

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



Representação tridimensional de pontes com recurso a robôs móveis de superfície

Daniel Peixoto Almeida

MESTRADO INTEGRADO EM ENGENHARIA ELETROTÉCNICA E DE COMPUTADORES

Orientador: Andry Maykol Gomes Pinto

Co-orientador: José Carlos dos Santos Alves

25 de Junho de 2018

Resumo

A utilização de veículos autónomos equipados de múltiplos sensores tem vindo a crescer em diversas áreas, em especial foco em serviços de inspeção de grandes estruturas que possam incorporar este género de sistemas nos procedimentos de modo a aumentar a rapidez, eficácia e segurança dos mesmos.

Os sistemas de sensorização incorporados nos sistemas robóticos variam de acordo com o tipo de inspeção, material da estrutura e ambiente em que estão inseridos. Por exemplo, para análise visual em ambiente terrestre, a utilização de sensores de deteção ótica é bastante frequente já que estes fornecem grandes quantidades de dados com elevada rapidez que, com o devido processamento e auxílio de diferente informação sensorial, permite criar uma representação de um cenário de forma precisa e fiável.

Juntamente com a odometria do veículo, os dados captados por tecnologias óticas permitem reconstruir tridimensionalmente o cenário onde foi realizada a recolha. Para casos em que seja realizada a reconstrução de uma infraestrutura, o mapa resultante será uma ferramenta útil à análise visual da mesma já que providencia um ponto de vista mais pormenorizado que pode auxiliar na deteção de falhas estruturais.

Assim, a primeira fase da dissertação passa por estudar e implementar algoritmos de processamento de dados recolhidos por tecnologias de sensorização ótica de modo a construir mapas tridimensionais de ambientes e estruturas terrestres. Nesta fase, o principal objetivo é reconstruir um mapa de fácil interpretação visual e minimizar o ruído e outras incoerências presente no mesmo. Numa fase seguinte, é pretendido realizar análises comparativas de mapas do mesmo cenário reconstruídos com dados recolhidos em diferentes ocasiões de modo a identificar possíveis alterações na zona e estrutura. Por fim, o mapa é referenciado geograficamente para que seja possível identificar o local que este representa.

Os resultados obtidos levam à conclusão que a utilização de tecnologias óticas na inspeção de grandes estruturas pode ser vantajosa já que permite, à distância, recolher rapidamente elevadas quantidades de dados que fornecem informação estrutural útil para análise de qualquer cenário terrestre.

Abstract

The use of autonomous vehicles equipped with multiple sensors has been growing in a number of areas, with special focus on inspection services of large structures that can incorporate this kind of systems in their procedures to increase speed, efficiency and safety.

Sensorization systems incorporated in robotic systems change with the type of inspection, structure material and environment in which they are inserted. For example, for visual analysis in terrestrial environment, the use of optical detection sensors is quite frequent due to the rapid collection of data that, with the right processing and aid of different sensory information, allows to create a representation of a scenario very accurately and reliably.

In combination with the vehicle's odometry, the data captured by optical technologies allow the reconstruction of three-dimensional maps of the scenario where the collection was performed. For cases in which the reconstruction of an infrastructure is carried out, the resulting map will be a useful tool for the visual analysis of the said infrastructure, since it provides a more detailed point of view that can aid in the detection of structural failures.

Thus, the first stage of the dissertation consists of studying and implementing optical data processing algorithms in order to construct three-dimensional maps of terrestrial environments and structures. At this stage, the main objective is to reconstruct an easy-to-interpret visual map and minimize the noise present in it. In a next phase, it is intended to perform comparative analyzes of maps of the same scenario reconstructed with data collected on different occasions in order to identify possible changes in the zone and structure. Finally, the map is geographically referenced so that it is possible to identify the site that this map represents.

The results obtained lead to the conclusion that the use of optical technologies in the inspection of large structures can be advantageous since it allows, at a large distance, to rapidly collect large amounts of data that provide useful structural information for the analysis of any terrestrial scenario.

Agradecimentos

Este documento representa o fim da vida de estudante. Uma etapa longa, difícil, cheia de incertezas e indecisões que, no fim, culminou numa sensação de objetivo cumprido. Sem sentimentos de culpa nem arrependimentos, fiz o que queria e o que tinha de fazer muito graças ao apoio da minha família e das pessoas de que, acertadamente, me rodeei e que passo agora a agradecer.

Primeiramente, agradeço ao meu orientador Professor Andry Pinto pela disponibilidade, conhecimento transmitido e paciência durante esta dissertação. Um obrigado às Engenheiras Alexandra Nunes e Ana Gaspar por prontamente me ajudarem sempre que era necessário. Ao CRAS e todos os colegas e amigos com quem partilhei um canto do laboratório pela ajuda e pela constante troca de ideias.

Um agradecimento especial aos meus amigos que conheci durante os meus anos de infância e adolescência com quem literalmente convivo e converso diariamente. São um grupo de pessoas que sempre me apoiaram e tornaram este caminho mais suave, e que tenho a certeza que continuarão ao meu lado da mesma forma que continuarei do deles. A estes se juntam os agora engenheiros com quem eu desenvolvi boas amizades durante estes últimos 5 anos, com quem sempre pude contar quando eu precisava de auxílio a nível académico e com quem tive grandes e memoráveis momentos.

Por fim, agradeço às pessoas mais influentes na minha vida, às pessoas que sempre me indicaram o caminho correto, que me ensinaram a distinguir entre o certo e o errado, que sempre me deram tudo o que eu precisava e o que não precisava, às pessoas que me tornaram na pessoa que, com muito orgulho, eu sou hoje. Aos meus pais, irmão e avós, o meu mais sincero e sentido obrigado.

Daniel Peixoto Almeida

*“You should be glad that bridge fell down.
I was planning to build thirteen more to that same design”*

Isambard Kingdom Brunel

Conteúdo

1	Introdução	1
1.1	Contexto	1
1.2	Motivação	2
1.3	Objetivos	3
1.4	Estrutura do Documento	3
2	Revisão Bibliográfica	5
2.1	Métodos Tradicionais	5
2.2	Técnicas de Avaliação de Não Contacto	7
2.2.1	Aquisição	7
2.2.2	Processamento	9
2.3	Veículos Móveis	11
2.3.1	Inspeção de Pontes	11
2.3.2	Inspeção de Ativos Elétricos	15
2.3.3	Inspeção de Múltiplos cenários	16
2.3.4	Inspeção Subaquática	17
2.4	Conclusão	18
3	Mapeamento	19
3.1	Metodologia	19
3.1.1	Ferramentas Utilizadas	19
3.1.2	Dados Utilizados	22
3.1.3	Trabalho Passado	23
3.2	Algoritmo	23
3.2.1	Remoção de Ruído	25
3.2.2	Registo	28
3.2.3	Representação e Compressão de Dados	32
3.2.4	Manipulação do Mapa	35
3.2.5	Correção de Odometria	36
3.3	Análise Comparativa de Mapas	38
3.4	Georreferenciação	43
3.5	Reconstrução 3D de Pontes	44
3.6	Conclusão	46
4	Conclusão e Trabalho Futuro	49
4.1	Conclusão	49
4.2	Trabalho Futuro	51

Referências**53**

Lista de Figuras

2.1	Procedimentos de risco em inspeção de pontes	6
2.2	Inspeção de pontes realizadas pela BMS	7
2.3	Modelação de um hotel com recurso a fotogrametria	8
2.4	Nuvem de 100000 pontos 3D. Diferentes tons de cinzento correspondem a diferentes intensidades do laser refletido (retirado de [1]).	9
2.5	Nuvem de pontos inicial (à esquerda) e nuvem de pontos após segmentação (à direita) (retirado de [2]).	10
2.6	Configuração inicial (à esquerda) e configuração após correspondência de pontos (à direita) (retirado de [3]).	11
2.7	Ponte D. Luís I (à esquerda) e Ponte do Freixo (à direita).	12
2.8	Trajetória autónoma realizado pelo robô móvel (retirado de [4]).	12
2.9	Design completo do sistema (A: Georadar; B: Estrutura do robô; C: Sensores de resistividade elétrica; D: <i>Display</i> do Georadar (retirado de [4]).	13
2.10	Rodas do robô com cilindros magnéticos (retirado de [5]).	13
2.11	Robô CROC	16
2.12	Testes experimentais do <i>Zeabus</i> (retirado de [6]).	17
3.1	Representação da interação entre <i>hardware</i> e <i>software</i> do sistema.	20
3.2	Sistema de recolha de dados e referenciais de cada componente.	20
3.3	Representação da interação entre nós e tópicos no ROS.	21
3.4	Representação da interação entre nós e tópicos existentes no algoritmo implementado.	21
3.5	Local de recolha de dados em Campanhã, Porto. Imagem retirada de <i>Instant Google Street View</i> à latitude 41.149448 e longitude -8.584292.	22
3.6	Mapa resultante da concatenação de nuvens de pontos (nuvem representativa do ambiente presente em 3.5).	23
3.7	Esquema representativo do processamento aplicado a uma nuvem de pontos.	24
3.8	Exemplo ilustrativo de filtragem de ROR	26
3.9	Mapa sem aplicação de qualquer filtro de ruído (nuvem representativa do ambiente presente em 3.5).	26
3.10	Mapa com aplicação de filtro de mediana (nuvem representativa do ambiente presente em 3.5).	27
3.11	Mapa com aplicação de filtro ROR (nuvem representativa do ambiente presente em 3.5).	27
3.12	Mapa com aplicação de filtro SOR (nuvem representativa do ambiente presente em 3.5).	28
3.13	Gráfico indicativo da diferença posicional entre 29 nuvens de pontos consecutivas.	29
3.14	Esquema representativo da aplicação de ICP no algoritmo.	30

3.15	Comparação de resultados do registo de nuvens de pontos com ICP clássico (a cima) e GICP (a baixo).	31
3.16	Comparação de uma diferente perspectiva entre cenário real e mapa 3D baseado em GICP.	32
3.17	Representação ilustrativa de uma octree.	33
3.18	Mapa 3D resultante sem aplicação de <i>VoxelGrid</i> (nuvem representativa do ambiente presente em 3.5).	34
3.19	Mapa 3D resultante após aplicação de <i>VoxelGrid</i> com tamanho de <i>voxel</i> de 50 centímetros (nuvem representativa do ambiente presente em 3.5).	34
3.20	Mapa 3D final após primeiro teste de recorte.	35
3.21	Mapa 3D final após segundo teste de recorte (focado na árvore presente no recorte da Figura 3.20).	36
3.22	Exemplo ilustrativo da aplicação de uma rotação e translação num conjunto de pontos.	37
3.23	Gráfico indicativo da odometria medida e da corrigida para dados de Campanhã. .	38
3.24	Esquema representativo do algoritmo de fase dupla de comparação de mapas 3D.	39
3.25	Diferentes mapas 3D de Campanhã não alinhados.	40
3.26	Erro de correspondência entre os dois mapas 3D de Campanhã.	40
3.27	Registo de zona comum aos diferentes mapas.	41
3.28	Diferentes mapas 3D de Campanhã alinhados.	41
3.29	Ilustração representativa do cone de luz emitida pelo LiDAR	42
3.30	Esquema representativo do processo de georreferenciação do mapa 3D.	43
3.31	Mapa georreferenciado sob mapa mundo em ArcGIS.	44
3.32	Local de recolha de dados na FEUP. Imagem retirada de <i>Instant Google Street View</i> à latitude 41.177637 e longitude -8.594375.	45
3.33	Reconstrução 3D do cenário presente na Figura 3.33.	45
3.34	Mapa de ponte pedonal georreferenciado sob mapa mundo em ArcGIS.	46

Lista de Tabelas

2.1	Parâmetros do robô (retirado de [5]).	14
3.1	Comparação numérica entre métodos de mapeamento.	28
3.2	Comparação numérica entre métodos de registro.	31
3.3	Comparação numérica entre registro com e sem compressão do mapa.	35
3.4	Comparação numérica entre diferentes recortes de mapa.	36
3.5	Média e desvio padrão de erro não acumulado.	37
3.6	Resultados da comparação entre mapas.	42
3.7	Características temporais do processo de georreferenciação.	43

Abreviaturas e Símbolos

3D	Tridimensional
AT	Alta Tensão
AUV	Autonomous Underwater Vehicle
BMS	Byggeriets Maskin Stationer A/S
DSLR	Digital Single-lens Reflex
FEUP	Faculdade de Engenharia do Porto
GICP	Generalized Iterative Closest Point
GIS	Geographic Information System
GPS	Global Positioning System
ICP	Iterative Closest Point
IMU	Inertial Measurement Unit
LiDAR	Light Detection And Ranging
MAT	Muito Alta Tensão
MT	Média Tensão
NaN	Not a Number
OpenCV	Open Source Computer Vision Library
PCL	Point Cloud Library
REFER	Rede Ferroviária Nacional
ROV	Remotely Operated Vehicle
ROS	Robot Operating System
RTK GPS	Real-Time Kinematic Global System Positioning
UAV	Unmanned Aerial Vehicle
WGS84	World Geodetic System 1984

Capítulo 1

Introdução

O presente capítulo tem como objetivo introduzir o tema "Representação tridimensional de pontes com recurso a robôs móveis de superfície". Primeiramente na secção 1.1 é realizada uma contextualização do tema da dissertação, seguido da motivação inerente ao desenvolvimento do projeto na secção 1.2, apresentação dos objetivos do projeto na secção 1.3 e, por fim, na secção 1.4 é exposta a estrutura do documento.

1.1 Contexto

A utilização de sistemas robóticos com tecnologias de sensorização acoplados têm vindo a estar cada vez mais presentes em qualquer indústria ou serviço que tenha o objetivo de aumentar a eficácia e rapidez dos seus processos. O aumento de segurança em procedimentos de elevado risco é outro fator bastante apelativo.

A inspeção de grandes estruturas está inserida no conjunto de serviços supra-mencionados. É cada vez mais frequente o uso de drones ou robôs com vários sistemas de sensorização a adquirir os mais diversos dados, armazena-los e/ou transmiti-los em tempo real para auxiliar o técnico responsável da inspeção. Deste modo, surgem diversos veículos aéreos ou terrestres que podem ser controlados remotamente por um operador ou executar trajetórias de forma autónoma. Estes veículos podem ser utilizados para analisar superfícies de grandes estruturas através de métodos que não envolvam contacto com a mesma, para verificar a condição interna dos materiais da estrutura ou até para observação de locais de difícil acesso a um humano. Qualquer que seja a aplicação, estas tecnologias conferem maior segurança a um processo de inspeção e permitem com que se obtenha dados precisos.

A confiabilidade dos dados é resultado do procedimento de aquisição e processamento dos mesmos. Para atingir resultados positivos deve-se ter em consideração a precisão dos sensores utilizados e diversas outras variáveis externas ao sistema de sensorização, por exemplo, movimentos inesperados do veículo móvel. Ou seja, os resultados de uma inspeção dependem diretamente da capacidade de um sistema adquirir e processar informação com exatidão e precisão.

Em suma, aumentar a segurança, rapidez e fiabilidade dos procedimentos de inspeção são os fatores que promovem, na área, a utilização de tecnologias robóticas e de sensorização à distância. Desta forma, também o projeto de dissertação irá ser desenvolvido com estes aspetos em consideração. Os maiores esforços serão direcionados à aquisição e processamento de dados, de modo a maximizar fiabilidade dos resultados das campanhas de recolha de informação.

1.2 Motivação

Em Portugal são facilmente encontradas estruturas construídas entre finais de século XIX e meados de século XX. Ponte de D. Maria Pia no Porto (inaugurada em 1877), a Ponte Rodo-Ferroviária de Viana do Castelo (inaugurada em 1878), a Ponte de D. Luís I no Porto (inaugurada em 1886) e a Ponte 25 de Abril em Lisboa (inaugurada em 1966) são alguns exemplos de pontes bastante antigas que ainda se encontram em funcionamento. A manutenção destas estruturas é crucial de forma a evitar tragédias como a que ocorreu no dia 4 de Março de 2001 na localidade de Entre-os-Rios, onde a Ponte Hintze Ribeiro (inaugurada em 1887) colapsou. Portanto, uma frequente e fiável monitorização destas construções é absolutamente necessária. Porém, ao contrário do que seria esperado, o investimento em monitorização e manutenção de infraestruturas em Portugal, segundo um estudo europeu¹ realizado em 2014, tem vindo a diminuir significativamente desde a década anterior. Esta ocorrência não é única na Europa e é também observável em países como Itália, Espanha, Irlanda e Eslovénia, países que tal como Portugal, foram fortemente afetados pela mais recente crise económica. A diminuição de investimento na prática de monitorização e preservação de pontes deve-se maioritariamente aos custos elevados associados. Assim, é esperado que estes custos e a falta de segurança, sejam diminuídos com a implementação de novas tecnologias.

Métodos tradicionais de inspeção envolvem análise visual e utilização manual de equipamentos de teste de materiais, o que para grandes estruturas é dispendioso temporal e economicamente (ver secção 2.1). Como exemplo, a Rede Ferroviária Nacional (REFER) realiza inspeções a pontes ferroviárias meramente visuais anualmente e inspeções mais detalhadas de cinco em cinco anos [7].

Para além dos procedimentos de monitorização estrutural apresentarem baixo nível de segurança, por vezes, também obrigam à interrupção parcial ou total da estrutura, por exemplo, corte do trânsito de uma ponte para realização de testes no tabuleiro superior da mesma. Este género de inconvenientes são eliminados caso os testes possam ser realizados a grandes distâncias. Métodos de aquisição de dados que não envolvem contacto com a superfície da estrutura, para além de não afetar o funcionamento normal da mesma, têm como vantagem a rápida e eficaz aquisição de

¹Parlamento Europeu. "EU Road Surfaces: Economic and Safety Impact of the Lack of Regular Road Maintenance". [http://www.europarl.europa.eu/RegData/etudes/STUD/2014/529059/IPOL_STU\(2014\)529059_EN.pdf](http://www.europarl.europa.eu/RegData/etudes/STUD/2014/529059/IPOL_STU(2014)529059_EN.pdf). Acesso em Junho de 2018.

dados e a sua facilidade de interpretação [8]. A associação entre métodos de avaliação de superfícies e de materiais a veículos remotamente controlados é também bastante vantajosa, visto que proporciona maior segurança e rapidez em serviços de inspeção.

1.3 Objetivos

O principal objetivo do projeto de dissertação passa pela promoção de novas soluções tecnológicas e metodologias de inspeção visual de infraestruturas de grandes dimensões como, por exemplo, pontes. Assim, a presente dissertação pretende apresentar uma metodologia de reconstrução de um mapa tridimensional (3D) de uma estrutura, utilizando os dados recolhidos por uma tecnologia de deteção ótica. De modo a obter um mapa 3D de elevada qualidade torna-se necessário organizar e tratar o conjunto de dados de forma a remover ruído e pontos incoerentes, bem como, otimizar o processo de junção das nuvens de pontos. A gestão de memória e poder computacional do algoritmo de mapeamento serão fatores a ter em consideração devido ao elevado número de dados utilizados na reconstrução do mapa. Por fim, é esperado georreferenciar cada ponto presente no mapa 3D final de modo a ser possível o inserir num *Geographic Information System* (GIS).

Pretende-se tirar proveito da diversidade de tecnologias e algoritmos de aquisição e processamento de dados já existentes para obter uma representação 3D do ambiente observado que possibilite extrair e quantificar informação relevante e de fácil interpretação. Realizado o estudo e implementação do algoritmo, será necessário validar os seus resultados, recorrendo a um largo conjunto de dados recolhidos em diferentes cenários como estruturas ferroviárias e pontes.

1.4 Estrutura do Documento

O documento está dividido em 5 capítulos. Neste capítulo é realizada uma introdução ao tema, revelando o contexto, a motivação e os objetivos da dissertação.

No capítulo 2 está exposto um conjunto de métodos tradicionais e não tradicionais frequentemente associados a monitorização de estruturas de grande envergadura, bem como uma variedade de sistemas de veículos móveis utilizados para esse mesmo fim.

O capítulo 3 está presente a descrição detalhada de todo o processo de mapeamento 3D. Aqui são apresentados os diversos testes realizados até à finalização do projeto.

Por fim, o capítulo 4 lista um conjunto de propostas para trabalho futuro e conclusões gerais do estudo e projeto desenvolvido.

Capítulo 2

Revisão Bibliográfica

Neste capítulo estão presentes os diversos métodos utilizados para monitorizar grandes estruturas. Primeiramente, na secção 2.1, são especificados os procedimentos mais elementares da área. Na secção 2.2 são mencionadas algumas técnicas de análise de estruturas à distância e especificados alguns algoritmos de processamento de nuvens de pontos. O que pode ser designado de estado da arte de inspeção de grandes estruturas está presente na secção 2.3, onde são encontrados múltiplos exemplos de sistemas robóticos utilizados nos dias de hoje.

2.1 Métodos Tradicionais

O método mais básico para monitorização de estruturas é o visual. É baseado em observações da superfície de uma construção com a finalidade de detetar qualquer tipo de falha ou desgaste no material. Este tipo de inspeção bastante elementar implica períodos de trabalho, custos e riscos elevados. Qualquer um destes aspetos pode ser observado nos procedimentos ilustrados na Figura 2.1. Mesmo que seja realizada uma inspeção completa a uma estrutura, os seus resultados não irão apresentar elevada confiabilidade visto que estes procedimentos podem ser fortemente afetados pelo erro humano.

Métodos de inspeção visual de uma estrutura levam a que os danos apenas sejam identificados quando a deterioração do material está visível, o que pode ser problemático caso a degradação ocorra do interior para o exterior. Ou seja, certas anomalias podem nunca ser detetadas. Com o objetivo de detetar danos não visíveis, sem danificar a estrutura, são então utilizados métodos de teste não destrutivos que fornecem informação adicional difícil de obter visualmente. Os testes não destrutivos são utilizados de acordo com o material da estrutura, por exemplo, aço [9] e betão [10]. Alguns exemplos de instrumentos e ensaios não destrutivos:

- **Esclerómetro** — O Esclerómetro, também conhecido como Martelo Schmidt, é um instrumento que tem como função ensaiar as propriedades elásticas, como a dureza superficial e resistência, de betão ou pedra.

- **Partículas magnéticas** — O ensaio com partículas magnéticas consiste em submeter um material ferromagnético (por exemplo, o ferro) a um campo magnético com o objetivo de detetar discontinuidades à superfície ou sub-superfície do mesmo.
- **Ultrassom** — Testes com ultrassom são realizados para analisar o comportamento de ondas ultrassónicas propagadas em dado material ensaiado. É usado especialmente para detetar corrosão nos diversos componentes metálicos de uma estrutura.

Estes testes não substituem os métodos visuais mas apenas os complementam, tornando o resultado da inspeção muito mais eficaz. Apesar de atualmente alguns destes instrumentos ainda serem utilizados, por si só não são capazes de eliminar questões relativas a segurança e rapidez, já que os procedimentos para realizar testes não destrutivos são semelhantes aos da Figura 2.1. Como exemplo concreto temos a *Byggeriets Maskin Stationer A/S* (BMS) que, há mais de 50 anos, realiza inspeções de pontes na Alemanha e noutros países europeus com auxílio de equipamentos como os que podem ser observados na Figura 2.2. Neste caso, a segurança dos trabalhadores é assegurada pela companhia, porém estes procedimentos demoram grandes períodos de tempo e implicam a interrupção do trânsito.

Desta forma, conclui-se que o cenário ideal passaria por acoplar os instrumentos para testes não destrutivos a diferentes tipos de equipamentos como a sistemas autónomos que se encontram descritos na secção 2.3.



Figura 2.1: Procedimentos de risco em inspeção de pontes



Figura 2.2: Inspeção de pontes realizadas pela BMS¹.

2.2 Técnicas de Avaliação de Não Contacto

Na secção 2.1 foi referido que as falhas na superfície de uma estrutura são detetadas visualmente durante procedimentos que colocam em causa a segurança dos técnicos de inspeção. Ou seja, o risco inerente a este género de procedimentos é uma das maiores problemáticas na área de inspeção de grandes estruturas. Sendo assim, tornou-se necessário encontrar uma alternativa viável ao método visual de modo a diminuir ou a eliminar por completo as preocupações relativas à segurança dos operadores. A deteção de anomalias à superfície de uma estrutura a média/grande distância foi uma das soluções encontradas para substituir o método visual. Esta envolve dois processos fundamentais, a aquisição de dados e o respetivo processamento, que quando completos permitem avaliar uma representação 3D de uma estrutura.

2.2.1 Aquisição

O processo de aquisição consiste em recolha de dados relevantes que, quando processados, permitem construir representações 3D de um ambiente e identificar objetos lá presentes. De seguida, apresenta-se alguns exemplos de técnicas de aquisição de dados utilizadas para avaliação de grandes estruturas.

Fotogrametria digital permite analisar e modelar a geometria de um objeto recorrendo a fotografias digitais. As mais recentes técnicas de análise fotogramétrica permitem examinar estruturas complexas e construir uma representação da mesma a partir de imagens como pode ser observado na Figura 2.3. Estes atributos propiciam a utilização de fotogrametria em avaliações de estruturas [11].

¹Byggeriets Maskin Stationer A/S. "Bridge inspection lifts // Infrastructure // Europe". www.bms.dk. <https://www.bms.dk/!ID47F2ECA3326C23DFC12581F000380E03>. Acesso em Junho de 2018.



Figura 2.3: Modelação de um hotel com recurso a fotogrametria².

Light Detection And Ranging (LiDAR) é um outro exemplo de tecnologia de deteção remota que permite calcular a distância a um objeto ao emitir e receber luz. Esta tecnologia ótica permite obter um vasto número de dados que possibilitam construir um modelo 3D do objeto, tornando-se possível observar as suas características superficiais. As aplicações do LiDAR são numerosas. Sistemas de LiDAR aéreos são frequentemente utilizados para mapeamento da superfície terrestre, permitindo obter informação sobre as suas características em dada zona, por exemplo, a sua elevação [12]. A utilização de sistemas de varredura a laser em veículos autónomos é também bastante comum, já que estes sistemas permitem auxiliar a navegação do veículo de modo a detetar e ultrapassar obstáculos no seu percurso [13] e a recolher dados relativos ao ambiente em seu redor como pode ser observado na Figura 2.4, respeitante a [1].

No que respeita a avaliação estrutural, a principal vantagem da utilização de LiDAR é a possibilidade de construir modelos 3D de uma estrutura complexa com excelente detalhe, que podem ser observados de diferentes ângulos e distâncias [14], desempenhando assim um enorme papel na avaliação e monitorização de estruturas como pontes [15] e edifícios [16].

²oddviz. "Hotel". oddviz.com. <https://www.oddviz.com/portfolio/hotel/>. Acesso em Junho de 2018.




Figura 2.4: Nuvem de 100000 pontos 3D. Diferentes tons de cinzento correspondem a diferentes intensidades do laser refletido (retirado de [1]).

2.2.2 Processamento

Após o processo de aquisição, deparámo-nos com conjuntos de dados não estruturados que necessitam de ser processados de modo a obter informação concreta. Existem diversas técnicas de processamento de dados, contudo, torna-se necessário optar pelas técnicas mais apropriadas ao tipo de dados que se pretende processar. De seguida, são apresentadas algumas dessas técnicas, com especial foco em processamento de nuvens de pontos adquiridos por tecnologias a laser.

Primeiramente, é de referir o processo de filtragem de nuvens de pontos dada a sua importância nas mais diversas aplicações, visto que permite extrair informação do espaço observado, por exemplo, a obtenção da elevação em áreas urbanas (edifícios, árvores, passeios e outros). A importância da filtragem no processamento de dados leva a um contínuo desenvolvimento de algoritmos que podem ser divididos em quatro tipos: morfologia matemática [17], rede triangular irregular progressiva [18], previsão linear [19] e segmentação [20, 21, 22]. Vários desses algoritmos foram testados em [23] e concluiu-se que, a nível de performance, diferentes cenários exigem diferentes algoritmos de filtragem.

Um dos principais desafios de processamento de dados recolhidos por uma tecnologia a laser é a segmentação, visto que os pontos na nuvem de pontos apresentam-se desorganizados,

dispersos e sem qualquer conexão entre si. O processo de segmentação consiste na divisão de um conjunto de pontos em subconjuntos mais pequenos e coerentes, baseado, por exemplo, na sua intensidade ou frequência, que posteriormente pode facilitar em reconhecimento de objetos e formas.

As metodologias e algoritmos mais populares de segmentação de nuvens de dados são de detecção de arestas [20], detecção de regiões [21] e híbrido [22]. Métodos de detecção de arestas retornam as fronteiras entre regiões ou objetos, que podem ser consideradas como as características mais básicas de uma imagem. Métodos de detecção de região começam com um ou mais pontos com características específicas e agregam-se a outros pontos com atributos idênticos, formando desta forma superfícies completas. Algoritmos híbridos recorrem a dois ou mais métodos de segmentação para construir modelos 3D de objetos mais pormenorizados.

O processo de segmentação pode também ser usado numa fase mais avançada do processamento de uma nuvem de pontos. Por exemplo, como pode ser observado na Figura 2.5, segmentação foi aplicada apenas com o propósito de distinguir as características do edifício mais facilmente. Assim, este processo pode também facilitar a detecção de possíveis anomalias presentes numa estrutura.



Figura 2.5: Nuvem de pontos inicial (à esquerda) e nuvem de pontos após segmentação (à direita) (retirado de [2]).

Correspondência de pontos é outra técnica de processamento bastante utilizada para reconhecimento de padrões que, muito sucintamente, consiste no alinhamento de dois ou mais conjuntos de pontos (ver Figura 2.6). O propósito deste processo é gerar modelos consistentes ou identificar objetos no espaço e estimar a sua posição. O leque de algoritmos baseados nesta técnica de processamento é vasto, mas o mais conhecido é *Iterative Closest Point* (ICP) [24, 25], que faz a correspondência entre todos os pontos com distância mínima entre si e pertencentes a nuvens de pontos diferentes. Desta forma, é possível reconstruir superfícies 3D a partir de diferentes conjuntos de pontos.




Figura 2.6: Configuração inicial (à esquerda) e configuração após correspondência de pontos (à direita) (retirado de [3]).

2.3 Veículos Móveis

A utilização de métodos não destrutivos é feita por técnicos especializados que por vezes têm de inspecionar certos pontos de difícil acesso em grandes estruturas, sendo necessário recorrer a procedimentos perigosos e de elevados custos. Também devido à elevada complexidade estrutural de certas obras pode ser impossível um humano aceder a locais específicos das mesmas. A solução para este problema passa pelo uso de veículos autónomos ou remotamente operados. Diferentes tipos de sensores são acoplados a estes veículos, dependendo do objetivo de cada sistema. Ou seja, cada exemplo que será de seguida apresentado não tem como objetivo fazer uma total inspeção de uma estrutura, mas sim apenas a porções da mesma.

Nesta secção serão apresentadas diversas soluções reais para monitorização de grandes estruturas, utilizando veículos autónomos, como robôs, *Unmanned Aerial Vehicles* (UAV) e *Autonomous Underwater Vehicles* (AUV). A maioria dos exemplos seguintes são utilizados na inspeção de pontes, contudo poderiam ser adaptados para outras estruturas.

2.3.1 Inspeção de Pontes

Normalmente, pontes são estruturas de elevada complexidade como as que podem ser observadas na Figura 2.7. Portanto, uma inspeção correta e completa das mesmas é um processo de extrema dificuldade. De seguida, serão apresentados alguns sistemas utilizados para avaliar diferentes porções e tipos de pontes.

Como primeiro exemplo temos o sistema robótico autónomo desenvolvido pela Universidade Nevada, Reno (EUA) para monitorização do tabuleiro superior de uma ponte, presente em [4]. A avaliação do material é realizada com recurso a métodos não destrutivos, já que estes não causam dano à estrutura. O sistema é capaz de realizar uma inspeção economicamente vantajosa, comparado com outros métodos que obrigam a ponte a ser evacuada antes da inspeção. Adicionalmente, o sistema possui um algoritmo de *machine learning* e reconhecimento de padrões para deteção das vigas aço que constituem a estrutura da plataforma e o primário foco de avaliação. Todos os dados recolhidos são integrados e automaticamente processados de forma a gerar um relatório da condição estrutural da ponte em tempo real.



Figura 2.7: Ponte D. Luís I (à esquerda) e Ponte do Freixo (à direita).

A trajetória ilustrada na Figura 2.8 é um exemplo de um caminho que o robô móvel necessita de realizar para adquirir dados ao longo do tabuleiro superior da ponte. Desta forma, o robô móvel de 4 rodas com tração diferencial usado (ver Figura central em 2.9) percorre a totalidade da ponte, rodando quando necessário mudar a direção do seu movimento, minimizando movimentos desnecessários.



Figura 2.8: Trajetória autónoma realizado pelo robô móvel (retirado de [4]).

Para a recolha de dados em tempo real são utilizados três diferentes tecnologias não destrutivas equipadas no veículo:

- **Câmara *Digital Single-lens Reflex* (DSLR)** — Avaliação visual do tabuleiro superior da ponte e deteção de falhas superficiais.
- **Georadar** — Avaliação mais profunda da condição das vigas de aço que se encontram no interior do betão, que são a parte mais vital da ponte. O seu funcionamento é observado na Figura 2.9 à esquerda.

- **Sensores de resistividade elétrica (2)** — Avaliação da resistência do betão do tabuleiro superior da ponte, fornecendo mais informação acerca da sua corrosão. O seu funcionamento é observado na Figura 2.9 à direita.




Figura 2.9: Design completo do sistema (A: Georadar; B: Estrutura do robô; C: Sensores de resistividade elétrica; D: *Display* do Georadar (retirado de [4])).

Ainda dentro do tema de robótica em inspeção de pontes, apresenta-se o sistema robótico autónomo também desenvolvido pela Universidade Nevada, Reno (EUA) descrito em [5]. Este tem como propósito inspecionar pontes de aço, que constituem o segundo maior tipo de pontes existentes nos EUA. Novamente, o objetivo da utilização deste sistema é aumentar a eficácia e a segurança nas inspeções, que frequentemente são efetuadas manualmente.

O robô possui 4 rodas com cilindros magnéticos acoplados (ver Figura 2.10), conferindo uma permanente aderência à superfície metálica sem qualquer consumo energético. É capaz de suportar múltiplos sensores para aquisição de dados, navegação e mapeamento. Sensores de distância e de campo magnético são também integrados no sistema de modo a assegurar que o robô se move em segurança pelas superfícies de aço. Consultar Tabela 2.1 para mais características físicas do robô.




Figura 2.10: Rodas do robô com cilindros magnéticos (retirado de [5]).

A informação adquirida pelos sensores é transmitida para a estação para futuro processamento. De seguida, são listados os diversos sensores presentes neste sistema robótico e respetiva função:

- **Câmara de vídeo** — Captura e transmissão de imagem.

- **Câmara *time-of-flight*** — Câmara baseada em LiDAR que captura imagens com apenas um pulso de luz que podem ser processadas de forma a construir um mapa 3D do cenário em que o robô está inserido.
- **Sensores de efeito de Hall (8)** — Detecção de variações no campo magnético.
- **Sensores de infravermelho (4)** — Verifica se o robô se encontra sobre uma superfície de aço. Associados a um algoritmo que processa os dados destes sensores, permitindo que o robô não ultrapasse os limites da superfície.
- **Inertial Measurement Unit (IMU)** — Auxílio na localização do robô no ambiente de trabalho.
- **Hokuyo laser scanner** — Detecção de distância até aproximadamente 6 metros. Contribui para a deslocação segura do robô.

Tabela 2.1: Parâmetros do robô (retirado de [5]).

Comprimento	220.9 mm
Largura	130 mm
Altura	241.26 mm
Peso	6,35 kg (sem carga) e 9,07 kg (com carga)
Condução	4 rodas motorizadas
Controlador	Controlador embebido + computador de bordo

Por vezes, a utilização de veículos terrestres obrigam à interrupção do funcionamento normal da ponte durante o ato de inspeção. Esta problemática é ultrapassada com a solução exposta em [8] que recorre a veículos aéreos para deteção de delaminações na superfície da plataforma de uma ponte, sem ser necessário cortar o trânsito da ponte. Como os outros sistemas até agora apresentados, este também pretende melhorar a eficácia e rapidez do processo de avaliação da plataforma da ponte.

Normalmente, o UAV é pilotado remotamente por um técnico especializado, no entanto, é também possível realizar voos autónomos devido aos sensores de estabilização e controlo de voo integrados no sistema. A deteção de delaminações é também efetuada com recurso a tecnologias não destrutivas. A carga presente no UAV é a seguinte:

- **Sensores de auxílio ao voo autónomo** — Sensores de pressão, acelerómetro e giroscópio são utilizados para controlar e estabilizar o UAV durante o voo.
- **Global Positioning System (GPS)** — Geolocalização do UAV e georreferenciação das falhas detetadas.
- **Câmara visual** — Transmissão de vídeo da superfície sob o UAV em tempo real.
- **Câmara de infravermelhos** — Transmissão do gradiente da temperatura da superfície em vídeo e tempo real.

Tanto o vídeo a cor como o de gradiente da temperatura, são gravados e transmitidos diretamente para dois monitores presentes na estação de recolha de dados. Através da junção de ambos os vídeos, um algoritmo de processamento de imagem deteta as várias delaminações presentes numa superfície.

Por fim, é de salientar que os sistemas descritos nesta secção são desenhados para ser possível alterar ou adicionar tecnologias de sensorização de forma a ser possível realizar campanhas de recolhas de dados para diferentes materiais e/ou estruturas.

2.3.2 Inspeção de Ativos Elétricos

O UAV de asas rotativas presente em [26] e desenvolvido pelo Centro de Robótica e Sistemas Autónomos (CRAS) pertencente ao INESC TEC, está agora ao serviço da EDP e tem como propósito realizar a inspeção de ativos do setor elétrico como subestações, linhas de MT-AT-MAT, aerogeradores e barragens. Além de minimizar custos, o UAV em questão proporciona maior segurança e facilita o processo de monitorização, já que grande parte dos ativos são de difícil acesso.

Normalmente, o UAV é operado remotamente por um técnico responsável, contudo é possível que o veículo aéreo realize voos autónomos. Neste caso, a trajetória realizada é o mais horizontal possível e caso surja um obstáculo inesperado, o UAV desvia-se da sua trajetória original de forma a ultrapassá-lo. Aquando estes voos, são transmitidas imagens em tempo real para monitorização visual dos ativos elétricos.

São utilizados sensores com a capacidade de detetar anomalias específicas de ativos elétricos. A informação adquirida por estes sensores do sistema é processada e apresentada em formato de relatório numa plataforma interativa. Os sensores acoplados ao UAV usado pela EDP³ são os seguintes:

- **LiDAR** — Determinação de distâncias e representação de um mapa 3D do ambiente e obstáculos.
- **Câmara visual** — Gravação e identificação de falhas em componentes e estruturas.
- **Sensores de termografia e espetro visível** — Detecção de pontos quentes.
- **Sensores de ultravioleta** — Detecção do efeito de Corona.

Inicialmente este projeto foi desenvolvido para ser capaz de operar em diferentes cenários. Ou seja, os primeiros esforços centraram-se na deteção de obstáculos e mapeamento do ambiente. Sendo assim, esta tecnologia pode ser adaptada para outras aplicações, tornando-se necessário integrar diferentes tecnologias de sensorização que atendam às necessidades da estrutura a ser inspecionada.

³EDP Labeltec. "Drones: EDP Labeltec's new product". edplabeltec.com.
<https://www.edplabeltec.com/en/news/drones-edp-labeltecs-new-product>.

2.3.3 Inspeção de Múltiplos cenários

Apesar da possível adaptação dos sistemas até agora apresentados a outras aplicações, todos eles atuam num tipo de inspeção específica. O oposto é verificado com CROC⁴ (*Confined Space Inspection Climbing*), um sistema robótico com capacidade de auxiliar serviços de inspeção em diferentes cenários desenvolvido na Universidade de Tecnologia de Sydney (Austrália), descrito em [27]. É um robô autónomo com propriedades funcionais semelhantes ao 2º sistema robótico presente em 2.3.1, já que possui a capacidade de escalar paredes de aço verticais graças aos seus “pés” magnéticos, evitar obstáculos, previstos e não previstos, no seu caminho e recolher informação. A principal característica mecânica que este sistema apresenta é o facto do seu movimento se assemelhar ao de uma lagarta (ver Figura 2.11). O seu objetivo é operar em espaços pequenos e apertados, inacessíveis a humanos, existentes em pontes, torres de transmissão, cascos de navio ou plataformas petrolíferas. Adicionalmente, este sistema apresenta uma interface gráfica que permite a um técnico monitorizar a operação, observando a transmissão de imagem em tempo real.




Figura 2.11: Robô CROC⁵

Toda a informação sensorial adquirida é processada após a inspeção e comparada com dados de recolhas anteriores de forma a detetar diferenças, que podem indiciar falhas na estrutura. Por fim, é importante referir que o CROC trabalha em conjunto com drones autónomos que inspecionam o ambiente exterior da estrutura.

⁴Universidade de Tecnologia de Sydney. “Development of a Deployable Climbing Robot for the SHB Inspection and Condition Assessment”. uts.edu.au. <https://www.uts.edu.au/research-and-teaching/our-research/centre-autonomous-systems/cas-research/projects/development>. Acesso em Junho de 2018.

⁵SafeWork Wrap. “The robot making life easier for Harbour Bridge workers”. safeworkwrap.com. <https://safeworkwrap.com/2016/02/24/the-robot-making-life-easier-for-harbour-bridge-workers/>. Acesso em Junho de 2018.

2.3.4 Inspeção Subaquática

A monitorização de ambientes marinhos ou fluviais é uma tarefa de difícil concretização e que acarreta riscos para quem a realiza. Por estas razões torna-se comum a utilização de *Autonomous Underwater Vehicle* (AUV) equipado com múltiplos sensores essenciais à realização de procedimentos de observação do fundo oceânico, recolha de dados ou inspeção de estruturas subaquáticas. Em [6] está descrito um sistema AUV denominado *Zeabus* (ver Figura 2.12) e equipado com diversos sensores de navegação e deteção com a finalidade de ser utilizado em inspeção de oleodutos em ambiente subaquático ou terrestre, tornando-se num *Remotely Operated Vehicle* (ROV) para este efeito. A utilização deste género de tecnologia aumenta a segurança e facilita a inspeção subaquática dos oleodutos já que se elimina a necessidade de utilização de mergulhadores para efeitos de observação dos mesmos.



Figura 2.12: Testes experimentais do *Zeabus* (retirado de [6]).

O mapeamento de fundos oceânicos é também onde a dissertação de mestrado de Alexandra Nunes [28], investigadora do CRAS, se enquadra. Na dissertação está descrito todo o processo proposto de mapeamento 3D com recurso a informação sensorial proveniente de um sistema de visão estereoscópica com duas câmaras. O resultado final do processamento das nuvens de pontos é um mapa a cores do fundo oceânico que fornece informação relativa à textura do mesmo, sendo possível detetar diferentes objetos lá presentes. Posto isto, é imperativo analisar um possível paralelismo entre o processo de mapeamento de fundos oceânicos e o mapeamento de estruturas terrestres com recurso a nuvens de pontos recolhidas por uma tecnologia que não câmaras visuais, neste caso, o LiDAR.

2.4 Conclusão

A inspeção de estruturas é fundamental para a sua preservação e a utilização de métodos pouco eficazes e fiáveis pode resultar em acontecimentos catastróficos. A informação resultante de cada método ou instrumento descrito na secção 2.1 é muito restrita e obriga a longos períodos de trabalho para aquisição de dados em elevadas quantidades. Assim, torna-se essencial aplicar múltiplos métodos e instrumentos numa só inspeção de forma a maximizar a informação recolhida para posterior análise, que ainda pode não estar presente no ponto ideal de fiabilidade. De modo a substituir alguns dos métodos referidos, começaram a ser adotadas tecnologias de aquisição remota de dados para avaliação de superfícies e metodologias de processamento desses mesmos dados de forma a serem mais facilmente compreendidos e interpretados. A precisão dos procedimentos de aquisição e processamento de dados é bastante superior aos métodos tradicionais de avaliação de superfícies, podendo substituí-los por completo e, consequentemente, ultrapassar determinados problemas de eficácia na inspeção estrutural. Porém, as tecnologias de aquisição utilizadas nos exemplos mencionados em 2.2.1 encontram-se fixas num ponto terrestre, o que impossibilita a realização de uma inspeção completa a grandes estruturas. De forma a tornar as técnicas de sensorização à distância mais rápidas, seguras e abrangentes, estas foram acopladas a veículos móveis e autónomos. Isto também possibilita melhorar a segurança e eficácia de testes de materiais que implicam contacto com a estrutura, inspeção em espaços interiores e locais de difícil acesso. Apesar do claro avanço tecnológico ao longo dos anos, a maioria dos exemplos de veículos móveis apresentados são prototipais, com a exceção do UAV desenvolvido pelo o INESC TEC que já se encontra ao serviço de uma companhia (EDP) para inspeção de ativos elétricos. Este fator indica que ainda existe um certo ceticismo no que se refere à utilização de sistemas autónomos na área de inspeção.

Capítulo 3

Mapeamento

Concluída a fase de pesquisa e revisão bibliográfica presente no capítulo 2 será iniciada a descrição da abordagem ao problema e resultados obtidos. Assim, o presente capítulo encontra-se dividido em cinco secções: descrição das ferramentas e dados utilizados no decurso do projeto (secção 3.1), apresentação do algoritmo e especificação e comparação de métodos de processamento de dados aplicados (secção 3.2), comparação de mapas resultantes de diferentes recolhas no mesmo cenário (secção 3.3), apresentação do algoritmo de referenciação geográfica (secção 3.4), resultados da utilização do sistema e algoritmo para reconstrução 3D de uma ponte (secção 3.5) e conclusão do capítulo (secção 3.6).

3.1 Metodologia

O algoritmo de mapeamento subaquático descrito em [28] é o ponto de partida da presente dissertação. Ou seja, com base no que já foi realizado e testado, é esperado implementar e otimizar um algoritmo de reconstrução de mapas 3D de cenários e estruturas terrestres. Portanto, é necessário utilizar *hardware* próprio para a recolha dos dados necessários e um conjunto de ferramentas *software* para tratamento dos mesmos.

3.1.1 Ferramentas Utilizadas

De forma a atingir os diversos objetivos do projeto foi necessário recorrer a variadas ferramentas *hardware* e *software* com utilidade em diferentes fases do mesmo. Na Figura 3.1 é possível observar as diferentes interações intrínsecas ao sistema e na Figura 3.2 o sistema completo montado num veículo automóvel. No decurso deste projeto, o sistema de recolha de dados foi utilizado manualmente e nunca associado a qualquer veículo.

A primeira fase do projeto passou pela recolha dos dados que foram utilizados para efeitos de teste do algoritmo de processamento e mapeamento. As nuvens de pontos captadas pelo *Velodyne LIDAR*, uma tecnologia de deteção ótica remota, são os dados usados para a reconstrução do mapa final. À medida que o sistema *hardware* se desloca no espaço, um sistema *Real-Time Kinematic Global System Positioning* (RTK GPS) da *Swift Navigation* fornece informação relativa

à translação e velocidade da estrutura de recolha de dados, enquanto um *Inertial Measurement Unit* (IMU) indica a rotação dessa mesma estrutura. A rotação e translação são guardadas sempre que é captada uma nova nuvem de pontos, sendo este processo fulcral para a correta construção de um mapa de pontos e respetiva alocação a um referencial cartesiano. Duas câmaras Mako G-125 são utilizadas para captar imagem real do ambiente que está a ser analisado. Neste projeto, o vídeo captado é usado meramente para efeitos de auxílio visual do ambiente e nada interfere no funcionamento do algoritmo.




Figura 3.1: Representação da interação entre *hardware* e *software* do sistema.



Figura 3.2: Sistema de recolha de dados e referenciais de cada componente.

O processamento e mapeamento das nuvens de pontos são a base do projeto que está assente num sistema operativo robótico, *Robot Operating System* (ROS), que oferece abstração de *hardware*, controlo de dispositivos de baixo nível, gestão de pacotes e troca de mensagens entre nós. Esta última característica é baseada em publicadores e subscritores, isto é, dado nó pode subcrever tópicos onde são publicadas mensagens por outros nós, processar essa informação e ainda publicar os resultados em diferentes tópicos. As trocas de mensagens entre nós e tópicos estão representadas na Figura 3.3 que serve também como base explicativa das interações presentes no diagrama da Figura 3.4. Neste, é possível analisar os dois nós integrados no algoritmo do sistema e a forma como os mesmos comunicam com os diferentes tópicos existentes. O nó principal é o que processa os pontos recolhidos pelo LiDAR e publicados via *rosvbag*, uma ferramenta que permite gravar e republicar mensagens num tópico. Como resultado temos o mapa 3D final e um erro, ϵ , que representa a diferença entre a odometria captada e a odometria correta. O nó de transformação incorpora a informação sensorial proveniente do RTK GPS e do IMU, também publicada via *rosvbag*, aplicando uma matriz de transformação espacial a cada nuvem de pontos de entrada do nó principal. Adicionalmente, este nó de transformação publica a odometria com informação de translação e rotação medida pelo sistema durante a recolha de dados e a odometria corrigida baseada no erro recebido do nó de processamento.




Figura 3.3: Representação da interação entre nós e tópicos no ROS.

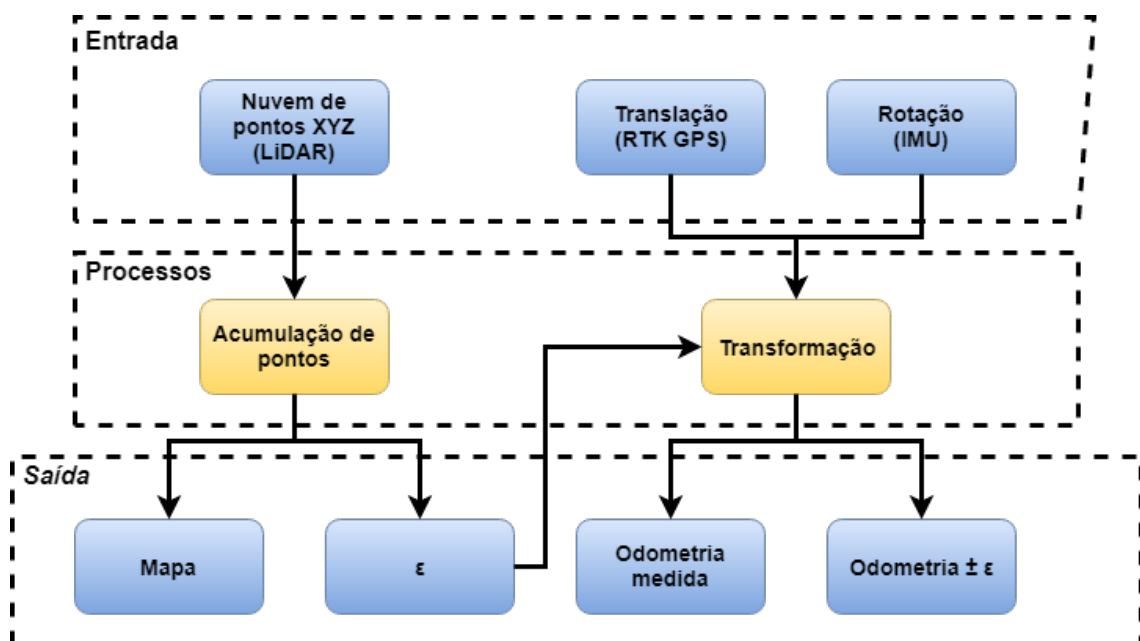


Figura 3.4: Representação da interação entre nós e tópicos existentes no algoritmo implementado.

Tanto o processo de mapeamento como todo o tratamento aplicado ao conjunto de dados recolhidos foi desenvolvido em C++ com recurso a bibliotecas disponíveis em *Point Cloud Library* (PCL) e *Open Source Computer Vision Library* (OpenCV), tecnologias de *software* de processamento de dados com diversos algoritmos *open-source* de filtragem de dados, estimação de características, reconstrução de superfícies, registo de imagem e nuvens de pontos, ajuste de modelos e segmentação. O processo de teste e implementação de alguns dos algoritmos mencionados será descrito no decurso do presente capítulo.

Por fim, o mapa 3D resultante do algoritmo será a entrada de um outro algoritmo desenvolvido em MATLAB, onde cada ponto é georreferenciado, ocorrendo uma transformação de coordenadas cartesianas (XYZ) para coordenadas geodésicas (latitude, longitude e altitude). O mapa resultante com novo tipo de coordenadas tem como finalidade ser importado para a plataforma *online* ArcGIS, um GIS onde é possível criar e usar mapas já existentes, compilar informação geográfica e armazenamento da mesma numa base de dados, partilha de informação geográfica e respetiva utilização em diversas aplicações.

3.1.2 Dados Utilizados

O foco principal do projeto é o processamento de nuvens de pontos relativas a pontes, contudo para a realização dos testes que estão descritos ao longo do presente capítulo, em Setembro de 2017, foram recolhidos dados na estação de Campanhã (Porto). O LiDAR tem a capacidade de captar pontos em 360° e um alcance acima dos 120 metros, possibilitando recolher uma elevada quantidade de dados. No entanto, os objetos de maior relevância no cenário de teste são os postes, árvores, edifícios e cartaz que podem ser observados na imagem 3.5. Foi exatamente nesse local que o sistema se deslocou para adquirir informação ótica, geográfica e de odometria.



Figura 3.5: Local de recolha de dados em Campanhã, Porto. Imagem retirada de *Instant Google Street View* à latitude 41.149448 e longitude -8.584292.

3.1.3 Trabalho Passado

Na dissertação de Alexandra Nunes [28], a junção das nuvens de pontos de entrada provenientes das câmaras visuais é realizada iterativamente através de concatenação das mesmas. A utilização deste método para unir as nuvens de pontos é computacionalmente leve e de simples compreensão e implementação. No entanto, para dados recolhidos por um LiDAR, a concatenação de nuvens de pontos resulta em mapas onde é apenas possível ter uma perceção básica das suas características e dos diferentes objetos lá presentes como pode ser observado na Figura 3.6. Isto deve-se ao facto da utilização única deste método não ser a mais eficiente já que com a acumulação iterativa de nuvens também o ruído se acumula. Erros provenientes de odometria também são ignorados, resultando numa inaceitável definição do mapa. Portanto torna-se necessário implementar algoritmos de remoção de ruído e registo de nuvens de pontos de forma a complementar este método de mapeamento.




Figura 3.6: Mapa resultante da concatenação de nuvens de pontos (nuvem representativa do ambiente presente em 3.5).

3.2 Algoritmo

Durante a fase de recolha de dados, estes são armazenados continuamente para posterior tratamento em modo *offline*. Isto permite que o tempo de execução do mapeamento e outras operações realizadas com os dados recolhidos possa ser maior desde que resulte em mapas mais precisos e visualmente perceptíveis. O relaxamento do objetivo de minimizar tempo de execução do algoritmo pode se tornar útil já que o tratamento dado às nuvens de pontos esquematizado na Figura 3.7 é computacionalmente pesado.

O algoritmo pode ser dividido em duas grandes fases. A primeira fase consiste no processamento iterativo das nuvem de pontos de entrada, a transformação espacial, reconstrução 3D, organização do mapa e cálculos auxiliares. Quando finalizada esta primeira fase, o mapa é exportado e guardado. Numa segunda fase, esse mapa é a entrada de um algoritmo de referência geográfica, para posterior inserção do mapa num GIS.

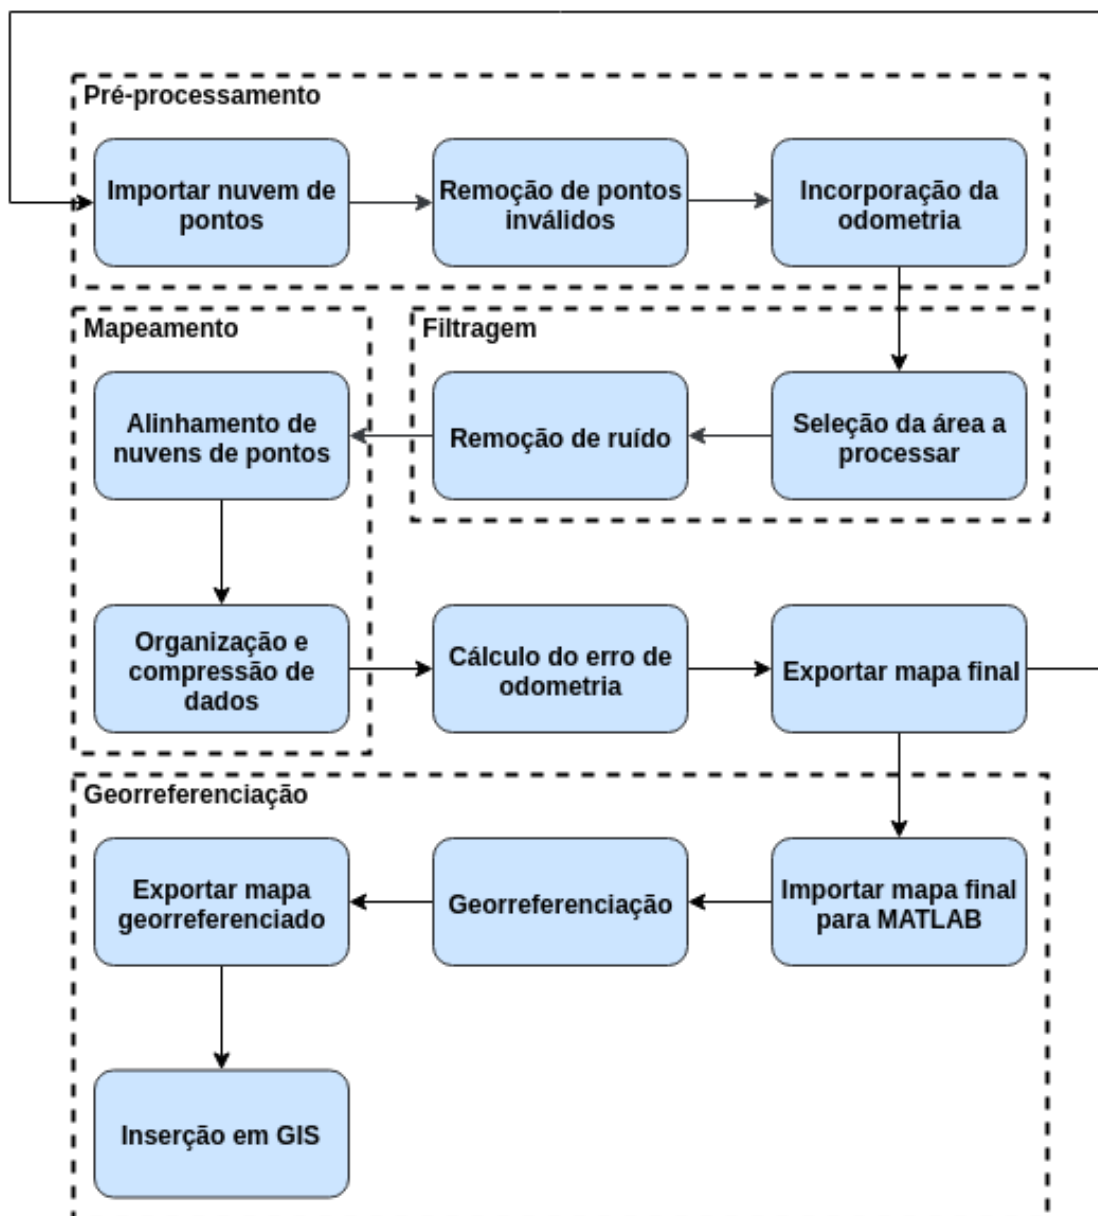


Figura 3.7: Esquema representativo do processamento aplicado a uma nuvem de pontos.

3.2.1 Remoção de Ruído

As nuvens de pontos geradas pelo LiDAR, devido a erros de medição e imprecisões, tanto apresentam valores inválidos classificados de *Not a Number* (NaN), como valores válidos mas que nada representam, denominado de ruído. A eliminação dos valores NaN é fundamental já que a presença dos mesmos numa nuvem de pontos coloca em causa o correto funcionamento de alguns dos algoritmos de processamento aplicados. Contudo, a extração destes valores NaN não é suficiente e com a acumulação de nuvens de pontos, também o ruído se acumula. A forte presença de ruído, como o que se observa na Figura 3.9, implica maior tempo de execução do processo de mapeamento e dificulta a interpretação visual do mapa 3D final. Assim, torna-se crucial eliminar estas irregularidades. A remoção de ruído foi a primeira etapa desse processamento onde foram testados alguns filtros, comparando-se resultados de forma a concluir qual o mais eficaz.

O filtro de mediana é o primeiro filtro de redução de ruído a ser analisado e é principalmente utilizado em algoritmos de processamento de imagem, como se observa em [29], ou sinais. Porém, já que o filtro de mediana se encontra disponível em biblioteca PCL, este foi implementado e testado para processamento de nuvens de pontos. O filtro de mediana efetua uma análise de todos os vizinhos de cada ponto, substituindo esse mesmo conjunto de pontos analisado pela sua mediana, eliminando os pontos mais divergentes numa dada vizinhança que provavelmente representam ruído. Contudo, ao comparar os resultados da Figura 3.9 e da 3.10 é possível constatar que o filtro ao ser diretamente aplicado na nuvem de entrada faz com que o ruído apenas seja reduzido e nunca completamente eliminado, permitindo que continua a ocorrer uma acumulação de pontos divergentes ao longo da execução do processo de mapeamento.

De seguida, foi testado o filtro *Radius Outlier Removal* (ROR) que analisa cada ponto individualmente, eliminando todos os que não apresentam um mínimo número de vizinhos dentro de um raio pré-definido. Para melhor entendimento deste filtro será necessário recorrer à Figura 3.8 onde é possível observar três diferentes pontos sob análise, amarelo, azul e verde. Para os três pontos foi definido um raio de análise d . O número de vizinhos mínimo que cada ponto é outro parâmetro que também é necessário ser definido à partida. Caso esse valor mínimo seja 1, apenas o ponto amarelo será eliminado. Se o valor for 2, tanto o ponto amarelo como o verde serão eliminados. O ponto azul em ambos os casos é mantido já que apresenta 4 vizinhos dentro do seu raio d . As nuvens de pontos usadas na fase de testes deste projeto apresentam um número de pontos na ordem dos milhares, dificultando a definição do valor mínimo de vizinhos que cada ponto deve possuir de forma a não ser considerado ruído. Este parâmetro mal calculado pode não só eliminar ruído mas também objetos pequenos mas relevantes. Na Figura 3.11 observa-se o mapa resultante da aplicação do filtro ROR diretamente na nuvens de dados de entrada.

Foi ainda estudado e testado um terceiro filtro, o *Statistical Outlier Removal* (SOR), que realiza uma análise estatística da vizinhança de cada ponto no conjunto de dados. Esta análise consiste no cálculo da distância média de cada ponto aos seus vizinhos. Todos os pontos que se apresentem para além do intervalo das distâncias médias globais calculadas e respetivo desvio padrão serão considerados como ruído e eliminados. Tal como no ROR, o filtro SOR tem como base dois cri-

térios pré-definidos, o número de vizinhos de cada ponto para qual se deve calcular a distância média e o fator multiplicativo do desvio padrão. Na Figura 3.12 observa-se o resultado da aplicação do filtro SOR na nuvem de pontos da Figura 3.9. Este filtro, não só remove o ruído como também remove os pontos mais incoerentes pertencentes a cada objeto, resultando num realce das suas características e consequente melhoramento visual.




Figura 3.8: Exemplo ilustrativo de filtragem de ROR¹.




Figura 3.9: Mapa sem aplicação de qualquer filtro de ruído (nuvem representativa do ambiente presente em 3.5).

¹PCL. "Removing outliers using a Conditional or RadiusOutlier removal". http://pointclouds.org/documentation/tutorials/remove_outliers.php. Acesso em Junho de 2018.




Figura 3.10: Mapa com aplicação de filtro de mediana (nuvem representativa do ambiente presente em 3.5).




Figura 3.11: Mapa com aplicação de filtro ROR (nuvem representativa do ambiente presente em 3.5).




Figura 3.12: Mapa com aplicação de filtro SOR (nuvem representativa do ambiente presente em 3.5).

Tabela 3.1: Comparação numérica entre métodos de mapeamento.

	Nº de nuvens	Nº de pontos	Tempo (segundos)
Soma s/ filtro	50	682438	42,9
Soma c/ Median	50	679120	58,3
Soma c/ ROR	50	660647	56,3
Soma c/ SOR	50	655273	52,6

Após visualizar os resultados dos diferentes filtros conclui-se que o SOR é o filtro que oferece o maior incremento de qualidade visual ao mapa. Devido à melhor definição dos objetos e redução de ruído, este filtro implica tempos de execução mais curtos, como é comprovado pelos resultados numéricos da Tabela 3.2.1. Esta indica o tamanho dos mapas consequentes e o respetivo tempo de processamento de 50 nuvens de pontos.

Com todos os testes e seus resultados em consideração foi definido que o filtro de ruído a utilizar na primeira fase de tratamento dos dados fosse o SOR.

3.2.2 Registo

Durante o percurso de recolha de dados realizado pelo sistema é expectável que ocorram alguns erros de medição por parte do *hardware*. De modo a estimar o erro de medição do LiDAR, realizou-se uma experiência que consistiu colocar o sensor imóvel, num ambiente interior inalterável, a recolher informação durante um curto período de tempo. Nestas condições qualquer erro que fosse detetado seria proveniente da tecnologia de deteção ótica. Após finalizada a experiência, procedeu-se ao cálculo da diferença entre nuvens de pontos consecutivas em X e Y. A Figura 3.13 prova que, de facto, existe uma pequena variação posicional do objeto completamente imóvel que não se verificou na realidade. Adicionalmente, segundo a sua ficha de especificações, o RTK GPS

também apresenta um erro de precisão de 1 e 1,5 centímetros, horizontal e verticalmente respetivamente, influenciando a odometria real do sistema. Assim, dada a existência destes erros, bem como outras possíveis variações imprevisíveis inerentes a testes em ambientes externos, torna-se necessário recorrer a algoritmos de registo de modo a eliminar estes mesmos erros.




Figura 3.13: Gráfico indicativo da diferença posicional entre 29 nuvens de pontos consecutivas.

Algoritmos de registo consistem na aplicação de uma transformação espacial a uma nuvem de pontos de modo a alinhar com uma outra de referência. Dentro desta classe de algoritmos de processamento de dados, o ICP é um mais utilizados. O processo de registo ocorre entre uma nuvem de pontos de referência estática e uma nuvem de origem que é transformada de forma a obter a melhor correspondência.

Ao longos das últimas três décadas surgiram diferentes propostas de implementação de ICP com o propósito de alinhar nuvens de pontos. Neste projeto, foram testados dois desses algoritmos existentes, o clássico método ICP [30] e um mais recente denominado de *Generalized Iterative Closest Point* (GICP) [31].

Da forma que o algoritmo ICP está implementado implica que este seja aplicado como está representado na Figura 3.14. Após a transformação da nuvem de pontos do sensor, ou seja, a junção da mesma com a odometria do sistema, é necessário alinhá-la com o mapa reconstruído até ao momento de forma a mitigar os erros de estimação de medição do sensor ótico e descolamento e, conseqüentemente, melhor a qualidade visual do mapa final. Caso a nuvem de entrada seja a primeira, esta alinha-se consigo mesma apenas com intuito de criar uma nuvem de referência que não se encontre vazia para futuras iterações. A nuvem resultante do algoritmo de ICP é apenas a nuvem de entrada alinhada com a nuvem de referência, isto é, o mapa. Portanto, de forma a completar esse mesmo mapa é necessário juntar a nuvem alinhada à nuvem de referência. Este processo é repetido para cada nuvem de entrada e realizado após a remoção de ruído descrita em 3.2.1.

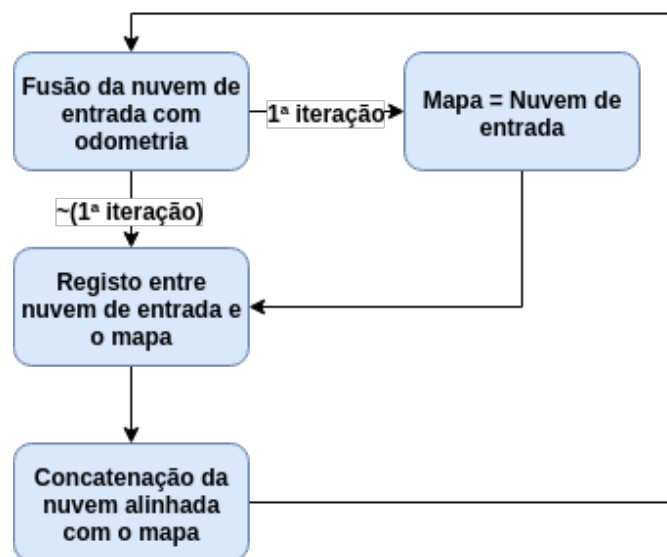


Figura 3.14: Esquema representativo da aplicação de ICP no algoritmo.

Como já referido, este procedimento de registo foi testado com utilização de ICP clássico e de GICP. Na Figura 3.15 é possível observar a diferença visual entre os dois métodos de registo, e concluir que, a este nível, a implementação de GICP teve melhores resultados. A melhor capacidade de alinhamento por parte de GICP deve-se à análise estatística realizada pelo mesmo modo a obter uma correspondência entre pontos mais correta e fiável.

A qualidade visual não foi a única métrica analisada. O tempo de execução e o tamanho do mapa final foram outros resultados considerados. Ao observar estes resultados numéricos, presentes na Tabela 3.2.2, verifica-se que ao aplicar métodos de registo ocorre um incremento no tempo de reconstrução do mapa 3D. A diferença desta mesma métrica entre o ICP clássico e o GICP é ainda mais notável, porém expectável em consequência da análise estatística que precede o processo de registo das nuvens de pontos ao utilizar GICP.

Na Figura 3.16, uma diferente perspetiva do cenário analisado e respetivo mapa 3D, verifica-se a existência de uma grande diversidade de objetos como árvores, postes, linhas férreas e edifícios. Apesar do ICP clássico ser de mais rápida execução, a heterogeneidade do ambiente faz com que o ICP clássico não realize um alinhamento aceitável, como se constata ao observar os postes e cartaz da metade superior da Figura 3.2.2. Esta adversidade juntamente com o facto do mapa 3D ser produzido *offline*, permitindo ignorar aqui questões relativas ao tempo de execução do processo completo, leva a implementação do GICP seja a escolha mais evidente para método de registo de nuvens de pontos.

Tabela 3.2: Comparação numérica entre métodos de registo.

	Nº de nuvens	Nº de pontos	Tempo (segundos)
Soma s/ ICP	25	327054	11,2
Soma c/ ICP clássico	25	331666	163,2
Soma c/ GICP	25	328668	2040




Figura 3.15: Comparação de resultados do registo de nuvens de pontos com ICP clássico (a cima) e GICP (a baixo).




Figura 3.16: Comparação de uma diferente perspectiva entre cenário real e mapa 3D baseado em GICP.

3.2.3 Representação e Compressão de Dados

A cada iteração de registo de nuvens de pontos, o número de pontos do mapa construído até ao momento aumenta. Esta contínua acumulação de pontos leva a uma maior utilização de memória e a um incremento do tempo de execução de cada ciclo de processamento dos dados, tornando o algoritmo computacionalmente pesado. Portanto, tornou-se necessário adotar soluções de modo a ultrapassar estes obstáculos.

Para uma mais rápida e eficiente acumulação e concatenação de nuvens de pontos, optou-se pela utilização de uma *octree*, uma estrutura em árvore que representa um particionamento espacial da nuvem de pontos, em que a sua raiz é uma caixa cúbica que engloba todos os pontos. A cada nível da árvore ocorre uma subdivisão do espaço como é observado na Figura 3.17 à

esquerda. Cada cubo é denominado de *voxel* e é subdividido até um determinado tamanho mínimo predefinido designado por resolução do *voxel*, que no algoritmo implementado, devido à precisão do LiDAR, está definido para 3 centímetros. Cada nó da árvore está interligado a outros 8 nós filhos como pode ser observado na Figura 3.17 à direita. Nós que não possuam filhos são as extremidades da árvore e são denominados como folhas.




Figura 3.17: Representação ilustrativa de uma octree.

Este módulo disponível em biblioteca PCL, tem como vantagem as eficientes pesquisas de vizinhos por diferentes métodos como a pesquisa por vizinhos dentro do mesmo *voxel*, a pesquisa pelos K vizinhos mais próximos e a pesquisa por vizinhos no interior de dado raio. O ajuste automático do tamanho da *octree* de acordo com o tamanho da nuvem de pontos, que é incrementado ciclicamente, é também uma importante característica deste método de organização de dados.

Apesar da utilização da *octree* auxiliar na diminuição do peso computacional é sempre possível melhorar este aspeto do algoritmo recorrendo a outros métodos de tratamento de dados. Com a acumulação iterativa de pontos à *octree*, o tamanho da mesma começa a aumentar, resultando em maiores tempos de execução do processo nas próximas iterações. Aquando a remoção de ruído das nuvens de pontos de entrada, parte dos dados que não são necessários ao mapa final são eliminados, diminuindo significativamente o tamanho do mapa no final do processo de construção. Porém, nem todos os pontos não necessários são classificados como ruído já que são adicionados frequentemente dados sobre objetos já observados anteriormente. Ou seja, a cada iteração existe uma acumulação de pontos não necessários relativos a objetos já detetados e presentes no mapa, tornando-se essencial diminuir o número de pontos da nuvem final. Isto é facilmente alcançado com recurso à biblioteca PCL *VoxelGrid* que gera uma grelha 3D de *voxels* semelhante a uma *octree* com a diferença que a primeira é subdividida uniformemente. Esta grelha é aplicada à nuvem de pontos e em cada *voxel* ocorre uma substituição dos pontos lá inseridos pelo seu centróide. Também à semelhança da *octree* é fundamental definir a resolução da grelha, que para valores

altos pode tornar os objetos presentes no mapa difíceis de analisar visualmente como pode ser observado na Figura 3.19. No entanto, a atribuição de um valor elevado para tamanho do *voxel* pode ter interesse em casos em que a finalidade do mapa seja outra que não a análise visual. Isto é, por exemplo, a representação 3D ser somente aproveitada para detecção e identificação de objetos no ambiente, sem necessidade de pormenorizar a reconstrução do mesmo.




Figura 3.18: Mapa 3D resultante sem aplicação de *VoxelGrid* (nuvem representativa do ambiente presente em 3.5).




Figura 3.19: Mapa 3D resultante após aplicação de *VoxelGrid* com tamanho de *voxel* de 50 centímetros (nuvem representativa do ambiente presente em 3.5).

Na Tabela 3.2.3 constata-se uma otimização do tempo de mapeamento em consequência da organização e compressão das nuvens de pontos. Contudo, é necessário ter em consideração que

a aplicação de *VoxelGrid* pode retirar confiabilidade ao mapa final já que lhe retirado um elevado número de pontos que podem conter informação crucial para análise estrutural.

Tabela 3.3: Comparação numérica entre registo com e sem compressão do mapa.

	Nº de nuvens	Nº de pontos	Tempo (segundos)
GICP s/ compressão	25	328668	2040
GICP c/ compressão	25	145730	1813,3

3.2.4 Manipulação do Mapa

A quantidade de informação captada pelo LiDAR *Velodyne* é bastante variada já que o seu ângulo de funcionamento é de 360° e tem alcance superior a 120 metros. Ou seja, aquando a construção do mapa 3D é possível que se esteja a mapear certas áreas do ambiente ou objetos lá presentes que não sejam do interesse do utilizador. Assim, surgiu a necessidade de adicionar ao algoritmo a possibilidade de recortar em X, Y e Z zonas do mapa que não tenham interesse. Desta forma, foi aplicado às nuvens de entrada, imediatamente antes ao processo de remoção de ruído, o filtro *PassThrough* que, de acordo com os limites inferiores e superiores fornecidos pelo utilizador, procede ao recorte das zonas de interesse. Este processo de manipulação de dados para além de moldar o mapa às necessidades de quem o analisa, também possibilita que o algoritmo execute mais rapidamente visto que a quantidade de pontos a processar é menor. Os resultados presentes na Tabela 3.2.4 referentes aos dois testes de recorte realizados (ver Figura 3.20 e 3.21) corrobora a afirmação anterior. A utilização desta funcionalidade do algoritmo é aconselhável caso não seja necessário analisar certas zonas do mapa, otimizando assim o processo de mapeamento.




Figura 3.20: Mapa 3D final após primeiro teste de recorte.




Figura 3.21: Mapa 3D final após segundo teste de recorte (focado na árvore presente no recorte da Figura 3.20).

Tabela 3.4: Comparação numérica entre diferentes recortes de mapa.

	Nº de nuvens	Nº de pontos	Tempo (segundos)
Sem recorte	25	145730	1813,3
1º recorte	25	45977	333
2º recorte	25	4001	37

Baseado no mesmo princípio e com recurso ao mesmo filtro de corte de nuvens de pontos, é também possível dividir o mapa final em camadas, seja relativo ao eixo X, Y ou Z. Esta funcionalidade diferencia-se da mencionada a cima já que esta não elimina qualquer tipo de informação e é aplicada diretamente no mapa 3D final já exportado. Este é um algoritmo complementar ao algoritmo principal de processamento de dados, que tem como entradas o mapa 3D em formato de ficheiro PCD, a dimensão em que vai ocorrer a divisão em camadas (X, Y ou Z) e o tamanho, em metros, de cada camada. Após a divisão do mapa, cada camada é exportada individualmente em formato PCD e devidamente numerada com os seus limites inferior e superior. A vantagem principal desta funcionalidade passa por manipular um mapa já existente sem ser necessário realizar novamente o processamento de dados e mapeamento.

3.2.5 Correção de Odometria

Como já mencionado em 3.2.2, devido a erros de medição por parte do sistema *hardware*, é comum que existam pequenas discrepâncias entre nuvens de pontos consecutivas. Ao implementar o GICP, essa diferença entre a nuvem de origem e a nuvem de referência é calculada, baseando-se em pontos comuns, e corrigida com a aplicação de uma matriz de transformação à nuvem de origem. Isto é, a nuvem de origem sofre uma rotação e uma translação, como ilustrado na Figura 3.22, de forma a ficar alinhada com a nuvem de referência.




Figura 3.22: Exemplo ilustrativo da aplicação de uma rotação e translação num conjunto de pontos.

A matriz de transformação, de onde é possível extrair a rotação e translação de correção, é uma das saídas do algoritmo de GICP e é calculada no fim de cada iteração do algoritmo. É deste modo que é determinado o erro entre a odometria medida e a correta. A junção desse mesmo erro com a odometria medida resulta numa odometria corrigida que é continuamente publicada num tópico de ROS que pode ser facilmente acedido pelo utilizador. O cálculo do erro de odometria permite obter informação da precisão do sistema como um todo, informando sobre a veracidade dos dados recolhidos.

Na Figura 3.23 verificámos que ao longo do percurso do sistema (esquerda para a direita) a diferença entre a odometria medida e a corrigida vai aumentando. Esta diferença será denominada de erro acumulado do sistema. Isto deve-se ao facto da primeira nuvem de pontos captada ser utilizada como nuvem de referência no processo de registo (GICP), permitindo a acumulação dos erros de cada componente do sistema ao longo do tempo. Uma posterior análise ao módulo do erro não acumulado, ou seja, a diferença entre correções realizadas em iterações de processamento consecutivas, permitiu obter os resultados estatísticos presentes na Tabela 3.2.5. Como esperado, a média do erro em X é maior já que a deslocação do sistema foi mais acentuada nesse eixo. É também necessário ter em consideração que nesta experiência o processamento foi parcial, isto é, nem toda a informação disponível foi processada. Um maior número de nuvens de pontos processadas, implicaria numa menor diferença entre erros acumulados.

Tabela 3.5: Média e desvio padrão de erro não acumulado.

	X	Y
Média	0,435	0,301
Desvio Padrão	0,376	0,311




Figura 3.23: Gráfico indicativo da odometria medida e da corrigida para dados de Campanhã.

3.3 Análise Comparativa de Mapas

O mapa 3D resultante do algoritmo de mapeamento tem como propósito fornecer informação visual de dada estrutura de modo a ser mais uma ferramenta disponível para o técnico de inspeção tirar conclusões sobre a sua condição. Independentemente da frequência dos serviços de inspeção, é esperado que seja realizada uma reconstrução 3D da estrutura sempre que esta for observada. Uma comparação meramente visual dos diferentes mapas representativos do mesmo cenário com um número elevado de pontos é uma má prática e de baixa fiabilidade. Portanto, o ideal passaria por recorrer a um método de comparação de mapas em que cada região seria analisada individualmente. Uma comparação entre dois mapas da mesma estrutura reconstruídos em diferentes ocasiões que apontasse diferenças consideráveis, poderia indicar falhas estruturais.

O processo de comparação de duas nuvens de pontos tem como base o registo dos dois mapas 3D envolvidos no processo. Considerando que há possibilidade dos mapas a comparar apresentarem um elevado número de pontos e o registo apenas se realiza uma vez, repetiu-se os testes com ICP clássico para este tipo de alinhamento devido à maior rapidez de processamento comparado com GICP. Na Figura 3.25 estão presentes duas nuvens de pontos recolhidas em Campanhã em diferentes ocasiões. A nuvem vermelha é a nuvem utilizada em todos os testes até ao momento e a azul é o mapa resultante de uma segunda campanha de recolha de dados. A diversidade de elementos e diferenças nas duas nuvens de pontos dificultam o processo de alinhamento, como se verifica na Figura 3.26. De modo a contrariar este obstáculo foi implementado um processo a duas fases (ver Figura 3.24), com necessidade de intervenção por parte de um utilizador. Numa primeira fase é selecionada uma característica comum aos dois mapas para recorte da zona onde essa

mesma característica está situada através do método de manipulação do mapa presente em 3.2.4. Ao comparar os dois mapas na Figura 3.25 a característica comum a ambos que mais se realça é o edifício. De seguida, é realizado o registo de apenas das áreas recortadas, resultando num alinhamento mais preciso como se constata na Figura 3.27. O registo parcial dos dois mapas além de ser mais rigoroso e rápido, permite obter uma matriz de transformação precisa que é aplicada, numa segunda fase, ao mapa completo. A matriz M , exclusiva para esta comparação, é apresentada ao utilizador que tem agora a função de a inserir no algoritmo e mudar o modo de alinhamento, um parâmetro *hardcoded* que define se o alinhamento entre os mapas é realizado via ICP ou através da aplicação direta de uma matriz de transformação. Na segunda fase deste processo semimanual, o alinhamento é executado nos mapas completos e com recurso à matriz M , resultando no mapa 3D presente na Figura 3.28.

$$M = \begin{bmatrix} R_{xx} & R_{yx} & R_{zx} & T_x \\ R_{xy} & R_{yy} & R_{zy} & T_y \\ R_{xz} & R_{yz} & R_{zz} & T_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \times \begin{bmatrix} X \\ Y \\ Z \\ W \end{bmatrix} =$$

$$= \begin{bmatrix} 0,8121 & 0,578573 & -0,0758703 & 22,0904 \\ -0,58114 & 0,813659 & -0,0155879 & 8,23836 \\ 0,0527124 & 0,0567514 & 0,997 & 4,45695 \\ 0 & 0 & 0 & 1 \end{bmatrix} \times \begin{bmatrix} X \\ Y \\ Z \\ W \end{bmatrix}$$

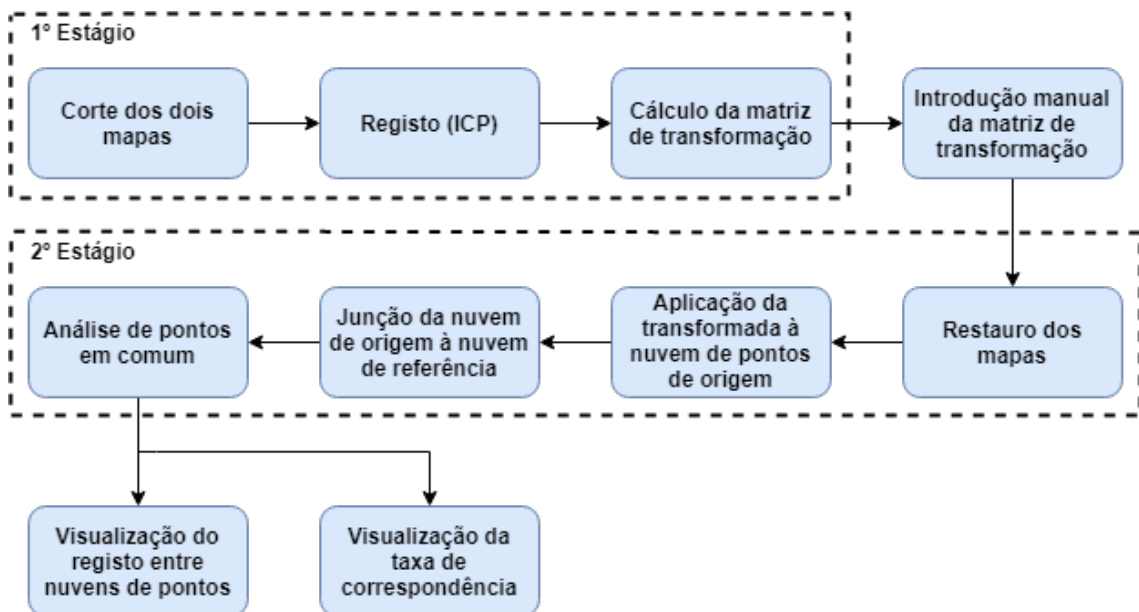


Figura 3.24: Esquema representativo do algoritmo de fase dupla de comparação de mapas 3D.




Figura 3.25: Diferentes mapas 3D de Campanhã não alinhados.




Figura 3.26: Erro de correspondência entre os dois mapas 3D de Campanhã.




Figura 3.27: Registro de zona comum aos diferentes mapas.




Figura 3.28: Diferentes mapas 3D de Campanhã alinhados.

Efetuada com sucesso a correspondência entre os diferentes mapas, é finalmente realizada a comparação de cada região dos mesmos com recurso a *octrees* e operações de pesquisa de vizinhos. Contudo, o efeito de cone efetuado pelo *laser* do LiDAR (ver Figura 3.29) dificulta o processo de comparação de objetos a grandes distâncias do sistema *hardware*. Por esta razão, para cada ponto da nuvem original é pesquisado numa vizinhança com raio de 50 centímetros um ponto pertencente à nuvem de referência. Caso um vizinho seja encontrado no interior desse raio, considera-se que ambos os pontos representam o mesmo ponto na realidade. Repara-se na Tabela 3.3 que para o procedimento de comparação entre os dois mapas de teste existe uma taxa de correspondência de aproximadamente 65%. Esta taxa está a um valor aceitável, considerando que o mapa de origem possui dados que não estão presentes no mapa de referência e que para objetos a maiores distâncias o raio de 50 centímetros possa não ser suficiente. É portanto aconselhável que aquando a nova recolha de dados de uma zona anteriormente analisada, seja esta realizada da mesma forma de modo a evitar grandes diferenças.




Figura 3.29: Ilustração representativa do cone de luz emitida pelo LiDAR².

Tabela 3.6: Resultados da comparação entre mapas.

Raio (metros)	0,05	0,5
Nº de pontos (azul)	33379	33379
Nº de pontos (vermelho)	145730	145730
Nº de pontos correspondentes	589	21565
Taxa de correspondência (%)	1,8	65

As limitações do LiDAR tornam este método falível e pouco fiável visto que apenas permite serem detetadas diferenças na ordem dos metros, possibilitando a não deteção de pequenas falhas.

²GlobalSpec. "LiDAR Gives Sight to Autonomous Vehicles". [globalspec.com. https://insights.globalspec.com/article/2013/lidar-gives-sight-to-autonomous-vehicles](https://insights.globalspec.com/article/2013/lidar-gives-sight-to-autonomous-vehicles). Acesso em Junho de 2018.

No entanto, é mais uma característica funcional oferecida por este *software* que facilita o processo de comparação visual de dois mapas 3D.

3.4 Georreferenciação

O mapa 3D fornece imensa informação visual acerca do ambiente que este representa. No entanto, este mapa não possui qualquer informação relativa ao seu local geográfico. Cada ponto da nuvem de pontos é representado por coordenadas cartesianas pertencentes a um referencial local gerado à volta de um módulo de referência do RTK GPS. Portanto, a solução passa por realizar uma transformação das coordenadas cartesianas (XYZ) para coordenadas geodésicas (latitude, longitude, altitude), oferecendo um acréscimo de interesse e utilidade ao mapa 3D. Em MATLAB está disponível uma função que realiza esta mesma transformação, desde que seja fornecido, como referência, um valor de coordenadas cartesianas e respetiva latitude, longitude e altitude. A transformação tem por base o *World Geodetic System 1984* (WGS84), um sistema que padroniza um referencial de coordenadas geográficas e uma superfície elipsoidal representativa da Terra. A partir do par de coordenadas de referência, a função realiza a conversão de cada ponto do mapa importado para MATLAB. A cada iteração de transformação, a nova coordenada é exportada e guardada em ficheiro de texto. A Figura 3.30 apresenta uma sistematização deste simples algoritmo iterativo. Na Tabela 3.4 são apresentados os resultados temporais do processo de georreferenciação de um mapa exemplo de 141389 pontos. Considerando que cada ponto é referenciado individualmente, um tempo de execução de aproximadamente 84,51 segundos é bastante aceitável. Dentro desta duração é considerado um período inicial onde ocorre a importação do mapa e definição do par de coordenadas de referência, e também a duração do ciclo de conversão de coordenadas. Cada iteração deste ciclo tem uma duração variável entre 0,0002 e 0,0008 segundos, causando também pequenas variações no tempo total de execução do processo.




Figura 3.30: Esquema representativo do processo de georreferenciação do mapa 3D.

Tabela 3.7: Características temporais do processo de georreferenciação.

Número de pontos	141389
Tempo inicial (segundos)	0,68
Tempo de georreferenciação (segundos)	0,0006
Tempo total de execução (segundos)	84,51

Com o mapa 3D agora referenciado geograficamente é possível inseri-lo no ArcGIS, um GIS *online*, de forma a ser possível o armazenar, analisar e manipular. Na Figura 3.31 está presente o resultado após importação do mapa para essa mesma plataforma.



Figura 3.31: Mapa georreferenciado sob mapa mundo em ArcGIS.

3.5 Reconstrução 3D de Pontes

Finalizada a fase de desenvolvimento e de testes do algoritmo de mapeamento e georreferenciação, realizou-se uma pequena campanha de recolha de dados com o sistema *hardware* descrito em 3.1.1 na Faculdade de Engenharia da Universidade do Porto (FEUP) em Paranhos, Porto. O objetivo principal da recolha será reconstruir um mapa da plataforma da ponte pedonal situada no campus da FEUP. Na Figura 3.32 está presente uma fotografia do cenário onde os dados foram recolhidos com indicação do caminho percorrido pelo sistema. Observa-se na Figura 3.33 a reconstrução 3D das zonas de maior interesse, o edifício, árvores e mais importante, o pavimento da plataforma da ponte. No entanto, no mapa, o pavimento encontra-se pouco denso devido ao sistema se ter deslocado perfeitamente na vertical e do ângulo de visão vertical do LiDAR ser de 15 graus. A solução passaria por realizar uma campanha de recolha a menor velocidade de forma a ser possível recolher um maior número de nuvens de pontos.

Na Figura 3.34 constata-se que mais uma vez a inserção do mapa final no ArcGIS teve um resultado positivo e bastante preciso.



Figura 3.32: Local de recolha de dados na FEUP. Imagem retirada de *Instant Google Street View* à latitude 41.177637 e longitude -8.594375.




Figura 3.33: Reconstrução 3D do cenário presente na Figura 3.33.




Figura 3.34: Mapa de ponte pedonal georreferenciado sob mapa mundo em ArcGIS.

3.6 Conclusão

O objetivo do presente capítulo passou por apresentar o método de trabalho adotado e descrever o algoritmo de mapeamento 3D implementado, bem como algumas das suas particularidades adicionais. Ao longo dessa mesma descrição foram expostos diversos resultados intermédios e finais com o propósito de indicar a qualidade do desempenho do sistema e algoritmo.

Primeiramente, foram estudados diferentes tipos de filtros de ruído de modo a tornar o processo de mapeamento mais leve e o seu resultado mais visualmente agradável. Com estas especificações em consideração, o filtro SOR apresentou os melhores resultados. A eliminação de ruído e valores NaN permite que o algoritmo de registo de nuvens de pontos seja mais rápido e fiável já que este não vai processar dados desnecessários. A importância da implementação de um algoritmo de registo passa pela necessidade de eliminar erros de medição e precisão do sistema *hardware*. A qualidade visual do mapa 3D final tem elevada influência na escolha do algoritmo de registo, e neste aspeto, o GICP apresentou excelentes resultados. No entanto, o custo da implementação de GICP é um aumento considerável do tempo execução total do algoritmo, que é cerca de 12,5 vezes maior em comparação com o ICP clássico, um semelhante algoritmo de registo testado. Apesar deste aumento de poder computacional ser considerado como aceitável para as condições em que o algoritmo é executado, foram estudadas opções para reduzir esta problemática. A organização e compressão do mapa 3D através do uso de *octree* e *VoxelGrid* respetivamente foi a solução

encontrada, reduzindo o tempo de execução, aproximadamente, em 11%. Adicionalmente, o mapa 3D final verificou-se de mais fácil análise e interpretação. Por fim, é dada a opção ao utilizador de seleccionar regiões de interesse no mapa, de forma a que tudo o resto seja ignorado pelo algoritmo de processamento, diminuindo o peso computacional do mesmo.

O mapa 3D resultante tem como principal utilidade a possibilidade de ser analisado visualmente. Porém, foi também implementado um algoritmo que regista e compara mapas do mesmo cenário ou estrutura, onde os dados foram recolhidos em diferentes momentos e circunstâncias. A componente de registo das nuvens de pontos revelou-se um desafio para cenários com uma elevada diversidade de características e objetos. Este obstáculo foi ultrapassado após implementação de um processo em que ocorre um registo parcial do mapa e que retorna os valores de rotação e translação, que numa segunda fase são aplicados ao mapa completo. A referência geográfica de cada ponto é uma outra característica do mapa 3D, que ao ser inserido num GIS, torna-se possível observar a localização real e exata de cada ponto.

Assim, conclui-se que ao aliar um sistema de recolha de dados com uma tecnologia *software* multi-funcional foi possível obter uma ferramenta com grande utilidade para a supervisão superficial de estruturas, o mapa 3D.

Capítulo 4

Conclusão e Trabalho Futuro

4.1 Conclusão

A monitorização e manutenção de estruturas de grande dimensão são processos dispendiosos temporal e economicamente e com diversos riscos associados. Por estes motivos, tem-se vindo a constatar uma diminuição de investimento em inspeções de pontes em Portugal e outros países europeus, o que pode ter resultados catastróficos. Atualmente, ainda prevalecem os métodos mais tradicionais de inspeção, como por exemplo a análise visual e utilização de maquinaria pesada. Dada a necessidade de ultrapassar as adversidades inerentes à inspeção de grandes estruturas e substituir os métodos atuais, verifica-se um aumento no desenvolvimento de sistemas de sensorização acoplados a veículos autónomos próprios para diferentes ambientes (terrestre, aéreo e subaquático) para auxílio em serviços de inspeção. Os sensores integrados em cada sistema dependem exclusivamente do tipo de informação que é necessário recolher para realizar com sucesso a avaliação pretendida. Para análise superficial de uma estrutura e seu mapeamento 3D foi utilizado um sistema com LiDAR e câmaras visuais, e para medição da odometria utilizou-se um IMU e RTK GPS. A utilização da informação de odometria durante o processo de mapeamento, permite que a localização das nuvens de pontos recolhidas pelo LiDAR no referencial cartesiano local não se altere caso o sistema mude de posição ou orientação. Esta informação de odometria é essencial para uma correta concatenação das várias nuvens XYZ recolhidas.

As nuvens de pontos são a base para a reconstrução do mapa 3D e é esperado que estas apresentem imprecisões e conjuntos de pontos que apenas diminuem a qualidade visual do mapa, sendo fundamental a sua remoção. Filtro de mediana, ROR e SOR foram os filtros estudados e testados, sendo o último o que apresentou melhores resultados. A sua capacidade de remover dados que não fossem coerentes com os objetos mais detalhados presentes no mapa revelou-se fulcral para obtenção de um mapa final de fácil de interpretação e permitiu, por conseguinte, diminuir o tempo de execução do algoritmo. Apesar de uma rápida execução não ser crucial visto que o mapeamento é realizado *offline*, é sempre positivo um melhoramento neste aspeto, especialmente com a implementação de GICP para registo de nuvens de pontos consecutivas. O GICP, devido à computação pré-registo de covariâncias de cada ponto, mostrou-se ser um método bastante lento. No entanto,

a qualidade do mapa resultante está consideravelmente acima do resultado do ICP clássico, que foi um outro algoritmo de registo experimentado. O GICP ainda possibilita obter a transformação espacial aplicada à cada nuvem de pontos com o propósito de a alinhar com o mapa reconstruído até ao momento. A matriz de transformação contém dados relativos à diferença entre a odometria medida e a estimada, dando uma perceção do desempenho e precisão do sistema completo. A nuvem alinhada resultante do GICP é iterativamente adicionada a uma *octree* e comprimida com recurso a *VoxelGrid* para melhor representação e organização da nuvem de pontos correspondente ao mapa final. A compressão do mapa tem como propósito facilitar o processo de alinhamento em iterações seguintes dado que o cálculo das covariâncias será mais rápido, contudo, uma compressão excessiva terá um custo na pormenorização do mapa. Por fim, é dada ao utilizador a opção de manipular o mapa antes ou depois do processamento de dados. A manipulação pré-processamento, como esperado, diminui o tempo de execução do algoritmo já que apenas áreas restritas serão processadas. Realizar a manipulação após o mapa estar já finalizado tem como vantagem recortar zonas de interesse sem ter de executar novamente o algoritmo de mapeamento.

A cada inspeção realizada a uma estrutura é esperado que este sistema seja utilizado, e recolhidos dados que possam ser utilizados para reconstrução de um novo mapa 3D da zona. Ter mapas do mesmo cenário recolhidos em diferentes alturas é vantajoso para comparação dos mesmos de modo a verificar possíveis diferenças estruturais. No entanto, as propriedades de funcionamento do LiDAR condicionam o método de comparação desenvolvido. Para longas distâncias, isto é, para objetos ao alcance máximo do LiDAR, os pontos recolhidos encontram-se demasiado dispersos para que possa ocorrer uma correspondência precisa entre os pontos dos diferentes mapas. A solução implementada no processo comparação, consiste numa pesquisa de vizinhos menos restrita com um raio entre 30 e 50 centímetros. Desta forma, apesar da baixa precisão, é dada uma perceção da taxa de semelhança entre os diferentes mapas.

A inserção de um mapa num GIS pode revelar-se de extrema importância e utilidade, porque lá, além de manipular e partilhar o mapa, é possível observá-lo sob o ambiente real que este representa. Porém, para isto ser possível foi necessário implementar um algoritmo de conversão de coordenadas cartesianas para coordenadas geodésicas. O funcionamento do mesmo é bastante simples e rápido que quando finalizado, exporta um mapa em que cada ponto se apresenta devidamente georreferenciado. Os resultados deste processo mostraram-se bastante positivos, tanto a nível temporal como a nível de precisão.

Em suma, o estudo efetuado ao longo da fase de revisão literária mostrou-se de extrema utilidade ao permitir retirar conclusões acerca do estado atual dos procedimentos de inspeção de estruturas e dar noções de que algoritmos implementar e de que como o fazer. Finalizado o desenvolvimento do algoritmo multi-funcional, conclui-se que este, com exceção da baixa precisão aquando a comparação entre diferentes mapas, apresentou resultados positivos, demonstrando ser possível empregar o sistema *hardware* em contexto real como ferramenta auxiliar em monitorização estrutural de pontes.

4.2 Trabalho Futuro

É seguro afirmar que os objetivos propostos no início do projeto de dissertação foram atingidos já que foi implementado com sucesso um algoritmo de mapeamento 3D de ambientes e estruturas terrestres. Contudo, é sempre possível e desejável aumentar a eficácia e robustez do algoritmo. Assim, são propostas as seguintes tarefas com o propósito de melhorar o que até agora foi realizado:

- realizar um maior número e variado de experiências em cenários com grandes estruturas, preferencialmente pontes;
- otimizar o tempo de execução da reconstrução do mapa 3D sem abdicar da qualidade visual atingida até ao momento;
- implementar um processo de comparação de mapas mais intuitivo e automático.

Referências

- [1] Michael Himmelsbach, Andre Mueller, Thorsten Lüttel, e Hans-Joachim Wünsche. Lidar-based 3d object perception. Em *Proceedings of 1st international workshop on cognition for technical systems*, volume 1, 2008.
- [2] Rizka Akmalia, Halim Setan, Zulkepli Majid, Deni Suwardhi, e Albert Chong. Tls for generating multi-lod of 3d building model. Em *IOP conference series: Earth and environmental science*, volume 18, página 012064. IOP Publishing, 2014.
- [3] Ting Chen, Baba C Vemuri, Anand Rangarajan, e Stephan J Eisenschenk. Group-wise point-set registration using a novel cdf-based havrda-charvát divergence. *International journal of computer vision*, 86(1):111, 2010.
- [4] Tuan Le, Spencer Gibb, Nhan Pham, Hung Manh La, Logan Falk, e Tony Berendsen. Autonomous robotic system using non-destructive evaluation methods for bridge deck inspection. Em *Robotics and Automation (ICRA), 2017 IEEE International Conference on*, páginas 3672–3677. IEEE, 2017.
- [5] Nhan H Pham e Hung M La. Design and implementation of an autonomous robot for steel bridge inspection. Em *Communication, Control, and Computing (Allerton), 2016 54th Annual Allerton Conference on*, páginas 556–562. IEEE, 2016.
- [6] Yodyium Tipsuwan e Phakhachon Hoonsuwan. Design and implementation of an auv for petroleum pipeline inspection. Em *Information Technology and Electrical Engineering (ICITEE), 2015 7th International Conference on*, páginas 382–387. IEEE, 2015.
- [7] G Sterritt. Review of bridge inspection competence and training. *Project Report: Final, Research Project: UG637, ATKINS*, 2009.
- [8] A Ellenberg, A Kontsos, F Moon, e I Bartoli. Bridge deck delamination identification from unmanned aerial vehicle infrared imagery. *Automation in Construction*, 72:155–165, 2016.
- [9] Takahide Sakagami, Yui Izumi, Daiki Shiozawa, Taisei Fujimoto, Yoshiaki Mizokami, e Taku Hanai. Nondestructive evaluation of fatigue cracks in steel bridges based on thermoelectric stress measurement. *Procedia Structural Integrity*, 2:2132–2139, 2016.
- [10] Marie-Aude Ploix, Vincent Garnier, Denys Breyse, e Joseph Moysan. Nde data fusion to improve the evaluation of concrete structures. *NDT & E International*, 44(5):442–448, 2011.
- [11] ME Stavroulaki, Belén Riveiro, GA Drosopoulos, M Solla, P Koutsianitis, e Georgios E Stavroulakis. Modelling and strength evaluation of masonry bridges using terrestrial photogrammetry and finite elements. *Advances in Engineering Software*, 101:136–148, 2016.

- [12] Yuan Feng, Zhang Ji-Xian, Zhang Li, e Gao Jing-xiang. Urban dem generation from airborne lidar data. Em *Urban Remote Sensing Event, 2009 Joint*, páginas 1–5. IEEE, 2009.
- [13] Harkishan Grewal, Aaron Matthews, Richard Tea, e Kiran George. Lidar-based autonomous wheelchair. Em *Sensors Applications Symposium (SAS), 2017 IEEE*, páginas 1–6. IEEE, 2017.
- [14] Christopher Watson, Shen-En Chen, Haitao Bian, e Edd Hauser. Three-dimensional terrestrial lidar for operational bridge clearance measurements. *Journal of Performance of Constructed Facilities*, 26(6):803–811, 2012. doi:10.1061/(asce)cf.1943-5509.0000277.
- [15] Shen-En Chen. Laser scanning technology for bridge monitoring. Em *Laser Scanner Technology*. InTech, 2012.
- [16] Chao Wang e Yong K Cho. Non-invasive 3d thermal modeling for buildings. Em *ICSDC 2011: Integrating Sustainability Practices in the Construction Industry*, páginas 474–481. 2012.
- [17] Shuwei Li, Huabo Sun, e Lei Yan. A filtering method for generating dtm based on multi-scale mathematic morphology. Em *Mechatronics and Automation (ICMA), 2011 International Conference on*, páginas 693–697. IEEE, 2011.
- [18] Chen Jie. Practice of airborne lidar point cloud filtering method based on triangulated irregular network. Em *Advanced Research and Technology in Industry Applications (WARTIA), 2014 IEEE Workshop on*, páginas 1284–1286. IEEE, 2014.
- [19] Karl Kraus e Norbert Pfeifer. Advanced dtm generation from lidar data. *International Archives Of Photogrammetry Remote Sensing And Spatial Information Sciences*, 34(3/W4):23–30, 2001.
- [20] Tengfei Bao, Jinlei Zhao, e Miao Xu. Step edge detection method for 3d point clouds based on 2d range images. *Optik-International Journal for Light and Electron Optics*, 126(20):2706–2710, 2015.
- [21] William J Beksí e Nikolaos Papanikolopoulos. 3d region segmentation using topological persistence. Em *Intelligent Robots and Systems (IROS), 2016 IEEE/RSJ International Conference on*, páginas 1079–1084. IEEE, 2016.
- [22] Liming Liu, Fengxuan Jing, Xiaoyao Xie, e Xiaojie Liu. Hybrid-based segmentation of massive three-dimensional point cloud data. Em *Electronic and Mechanical Engineering and Information Technology (EMEIT), 2011 International Conference on*, volume 9, páginas 4689–4692. IEEE, 2011.
- [23] George Sithole e George Vosselman. Experimental comparison of filter algorithms for bare-earth extraction from airborne laser scanning point clouds. *ISPRS journal of photogrammetry and remote sensing*, 59(1-2):85–101, 2004.
- [24] Hironobu Fukai e Gang Xu. Fast and robust registration of multiple 3d point clouds. Em *RO-MAN, 2011 IEEE*, páginas 331–336. IEEE, 2011.
- [25] Chi Yuan, Xiaoqing Yu, e Ziyue Luo. 3d point cloud matching based on principal component analysis and iterative closest point algorithm. Em *Audio, Language and Image Processing (ICALIP), 2016 International Conference on*, páginas 404–408. IEEE, 2016.

- [26] F. Azevedo, A. Oliveira, A. Dias, J. Almeida, M. Moreira, T. Santos, A. Ferreira, A. Martins, e E. Silva. Collision avoidance for safe structure inspection with multirotor uav. Em *2017 European Conference on Mobile Robots (ECMR)*, páginas 7 pp. –, Piscataway, NJ, USA, 2017.
- [27] David Pagano, Dikai Liu, e Kenneth Waldron. A method for optimal design of an inchworm climbing robot. Em *Robotics and Biomimetics (ROBIO), 2012 IEEE International Conference on*, páginas 1293–1298. IEEE, 2012.
- [28] Alexandra Pereira Nunes. Mapeamento e odometria visual em ambiente subaquático. Tese de mestrado, Faculdade de Engenharia da Universidade do Porto, 2017.
- [29] Haidi Ibrahim, Nicholas Sia Pik Kong, e Theam Foo Ng. Simple adaptive median filter for the removal of impulse noise from highly corrupted images. *IEEE Transactions on Consumer Electronics*, 54(4), 2008.
- [30] Paul J Besl e Neil D McKay. Method for registration of 3-d shapes. Em *Sensor Fusion IV: Control Paradigms and Data Structures*, volume 1611, páginas 586–607. International Society for Optics and Photonics, 1992.
- [31] Aleksandr Segal, Dirk Haehnel, e Sebastian Thrun. Generalized-icp. Em *Robotics: science and systems*, volume 2, página 435, 2009.